

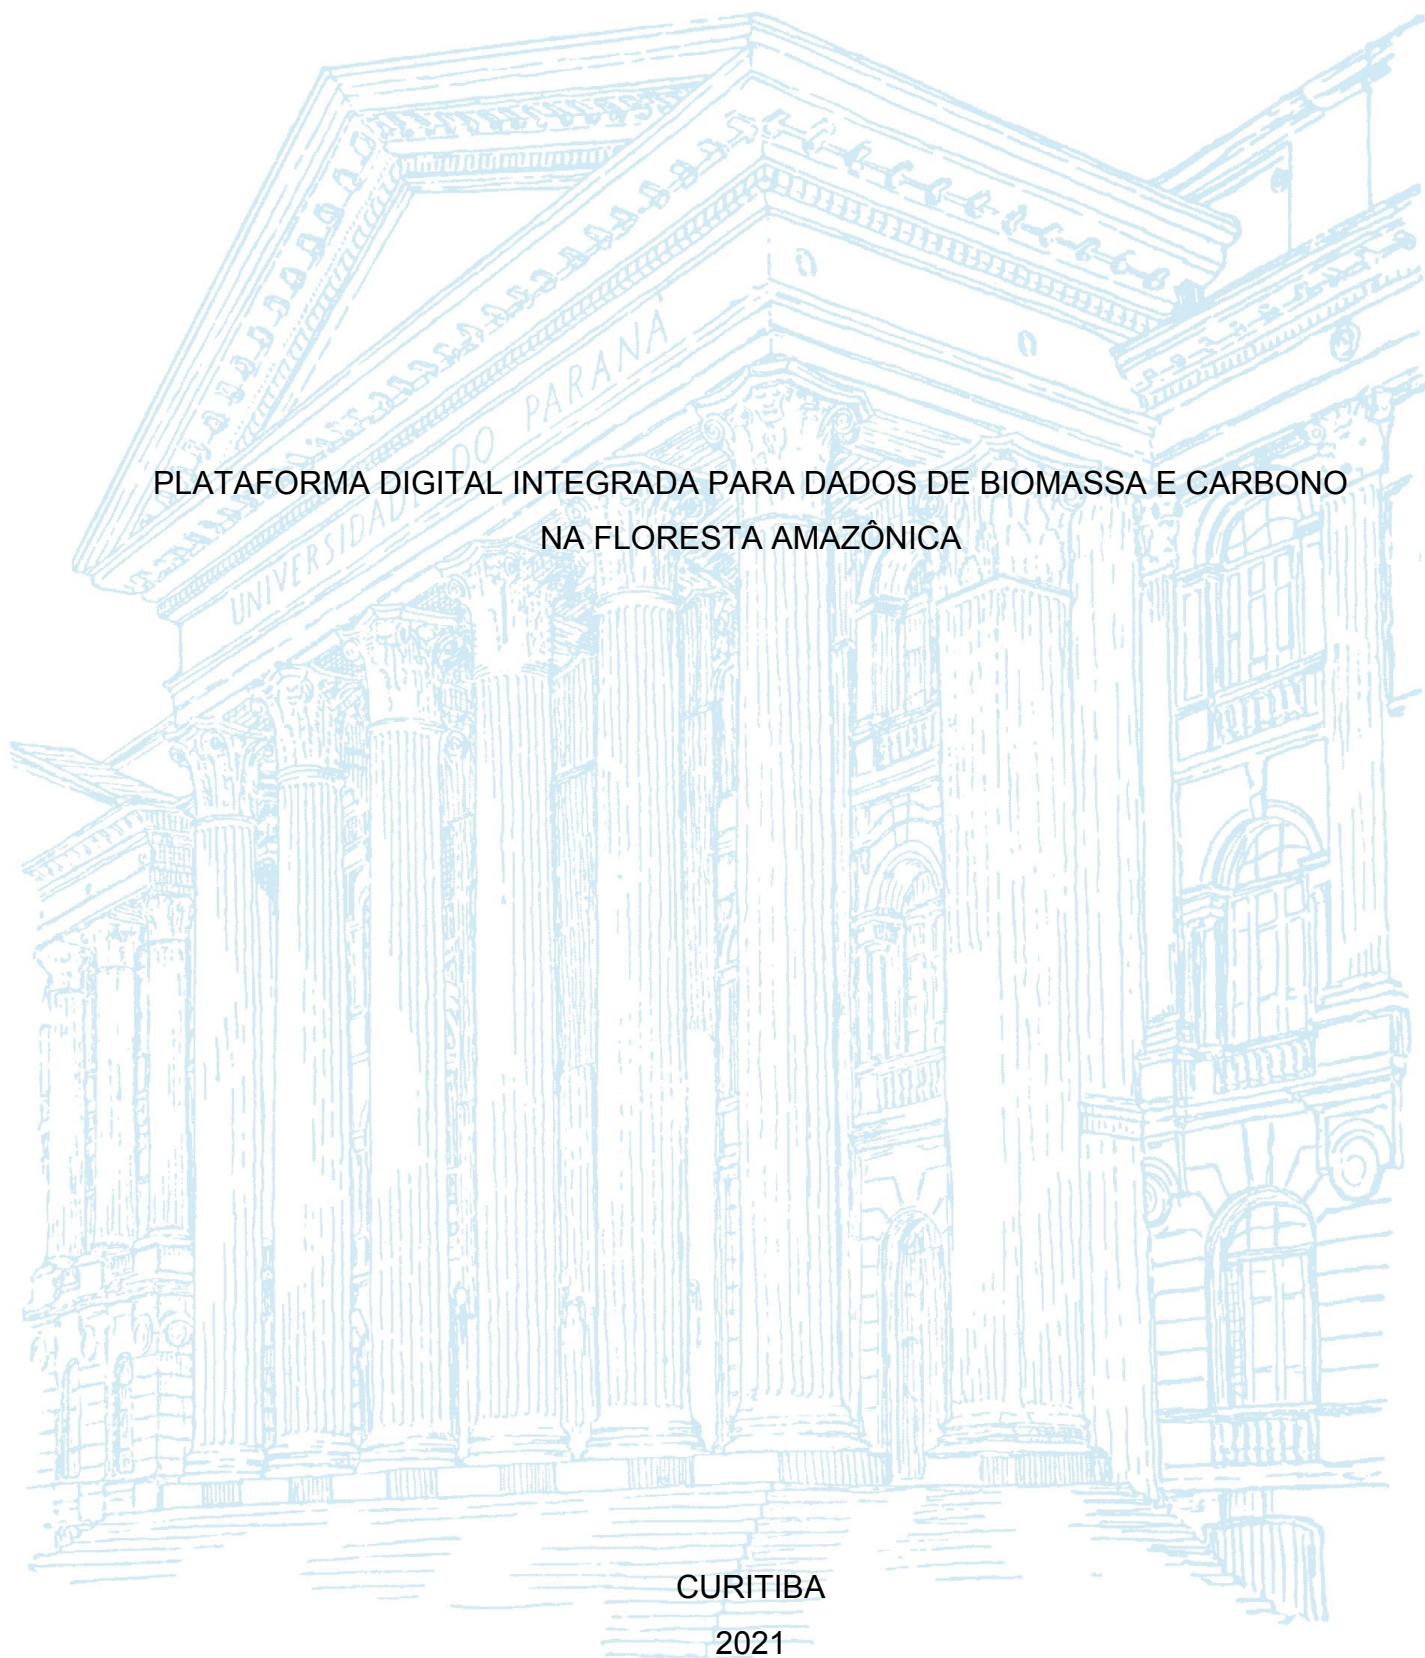
UNIVERSIDADE FEDERAL DO PARANÁ

LUANI ROSA DE OLIVEIRA PIVA

PLATAFORMA DIGITAL INTEGRADA PARA DADOS DE BIOMASSA E CARBONO
NA FLORESTA AMAZÔNICA

CURITIBA

2021



LUANI ROSA DE OLIVEIRA PIVA

PLATAFORMA DIGITAL INTEGRADA PARA DADOS DE BIOMASSA E CARBONO
NA FLORESTA AMAZÔNICA

Tese apresentada ao curso de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutora em Engenharia Florestal.

Orientador: Prof. Dr. Carlos Roberto Sanquetta

Coorientadores: Profa. Dra. Ana Paula Dalla Corte
e Prof. Dr. Jaime Wojciechowski

CURITIBA

2021

Ficha catalográfica elaborada pela
Biblioteca de Ciências Florestais e da Madeira - UFPR

Piva, Luani Rosa de Oliveira

Plataforma digital integrada para dados de biomassa e carbono na
Floresta Amazônica / Luani Rosa de Oliveira Piva. – Curitiba, 2021.
184 f. : il.

Orientador: Prof. Dr. Carlos Roberto Sanquetta

Coorientadores: Profa. Dra. Ana Paula Dalla Corte

Prof. Dr. Jaime Wojciechowski

Tese (Doutorado) - Universidade Federal do Paraná, Setor de Ciências
Agrárias, Programa de Pós-Graduação em Engenharia Florestal.

Defesa: Curitiba, 29/04/2021.

Área de concentração: Manejo Florestal.

1. Biomassa florestal – Amazônia. 2. Floresta – Amazônia. 3. Carbono.
4. Equações. 5. Algoritmos. 6. Sensoriamento remoto. 7. Teses.
I. Sanquetta, Carlos Roberto. II. Dalla Corte, Ana Paula.
III. Wojciechowski, Jaime. IV. Universidade Federal do Paraná, Setor
de Ciências Agrárias. V. Título.

CDD – 634.9

CDU – 634.0.548(811)

Bibliotecária: Berenice Rodrigues Ferreira – CRB 9/1160



MINISTÉRIO DA EDUCAÇÃO
SETOR DE CIÊNCIAS AGRÁRIAS
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA
FLORESTAL - 40001016015P0

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **LUANI ROSA DE OLIVEIRA PIVA** intitulada: **PLATAFORMA DIGITAL INTEGRADA PARA DADOS DE BIOMASSA E CARBONO NA FLORESTA AMAZÔNICA**, sob orientação do Prof. Dr. CARLOS ROBERTO SANQUETTA, que após terem inquirido a aluna e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutor está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 29 de Abril de 2021.

Assinatura Eletrônica

01/05/2021 20:51:18.0

CARLOS ROBERTO SANQUETTA

Presidente da Banca Examinadora

Assinatura Eletrônica

02/05/2021 16:04:44.0

HASSAN CAMIL DAVID

Avaliador Externo (null)

Assinatura Eletrônica

02/05/2021 19:47:04.0

JEAN PIERRE H. B. OMETTO

Avaliador Externo (INSTITUTO NACIONAL DE PESQUISAS
ESPACIAIS)

Assinatura Eletrônica

01/05/2021 17:21:27.0

ALEXANDRE BEHLING

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

01/05/2021 16:58:11.0

JOBERTO VELOSO DE FREITAS

Avaliador Externo (UNIVERSIDADE FEDERAL DO AMAZONAS)

Aos meus pais, Luiz Romero Piva e Myrian do Pilar Oliveira Rosa.
Aos meus avós paternos, Luiz Piva (*in memoriam*) e Dolores Romero Piva.
Aos meus avós maternos, Arnaldo Joaquim Figueira da Rosa (*in memoriam*)
e Avany Moreira Carneiro (*in memoriam*).

Dedico.

AGRADECIMENTOS

À Universidade Federal do Paraná e ao Programa de Pós-Graduação em Engenharia Florestal, pelo apoio institucional, logístico e de recursos humanos.

À CAPES, Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, e ao CNPq, Conselho Nacional de Desenvolvimento Científico e Tecnológico, agências financiadoras da minha bolsa de doutorado ao longo dos últimos quatro anos, as quais possibilitaram o desenvolvimento da minha pesquisa e contribuem para o desenvolvimento científico e tecnológico do nosso país.

Agradeço também à EMBRAPA e ao Projeto Paisagens Sustentáveis, coordenado pelo pesquisador Dr. Michael Keller, pela parceria e pela disponibilização dos dados da minha pesquisa. Na mesma linha, também gostaria de agradecer ao IBGE, no âmbito da plataforma BDIA, coordenada pela pesquisadora Dra. Luciana Mara Temponi de Oliveira, pelo excelente trabalho desenvolvido nesta plataforma, da qual extraí outro montante de dados utilizados em minha pesquisa.

Um agradecimento especial ao meu orientador, Dr. Carlos Roberto Sanquetta – um dos grandes especialistas e referências no nosso país em matéria de florestas e mudanças climáticas –, pela oportunidade e pelas inúmeras contribuições no presente trabalho, além de todos os ensinamentos e orientações repassadas.

Agradeço também aos meus coorientadores, Dr. Jaime Wojciechowski e Dra. Ana Paula Dalla Corte, pelos riquíssimos ensinamentos e contribuições em meu trabalho.

Aos mestres e amigos Prof. Dr. Alexandre Behling e Prof. Dr. Alessandro Camargo Angelo, que contribuíram de maneira expressiva e imensurável na minha formação profissional ao longo dos últimos anos de academia. Obrigada pelos momentos de descontração, como também pelas grandes discussões filosóficas e conselhos de vida.

À minha família, em especial aos meus pais, Luiz e Myrian, e minhas irmãs, Jade e Naiady, por sempre acreditarem em meu potencial e pelo apoio incondicional. Sem vocês, nada do que conquistei até agora teria sido possível.

Aos colegas do laboratório BIOFIX, Bruna, Marieli, Fran, Thiago, Deivison, Linamara, Manu, Hudson, Neto e Maria Emília, pela amizade e pelo incentivo constante, além dos momentos de descontração!

Aos amigos de longa data, Thiago, Nathi, Vini, Rorai, Regina, Elô, Ed, Camila, Tati, Gusso, Clover, Raquel, Thay, Marcos, Kakau e Magno, pelos conselhos e auxílios, tanto pessoais quanto profissionais, e pelo apoio e companheirismo de sempre.

Ao meu companheiro de vida, Rodrigo Medeiros Ribeiro, pelo apoio incondicional, amor e carinho, e por me incentivar e dar forças nos momentos em que mais precisei. Obrigada por sempre me lembrar de que “A felicidade pode ser encontrada mesmo nas horas mais difíceis, se você lembrar de acender a luz”.

Por fim, um agradecimento e homenagem especial aos pesquisadores e pesquisadoras desse país, os quais são a mola propulsora da ciência brasileira – incluindo meus brilhantes colegas de pós-graduação em institutos e universidades Brasil afora. Vocês, mesmo em meio a tantos cortes orçamentários, falta de incentivos e poucos recursos, persistem. Continuem lutando para que todas as camadas da sociedade possam ter acesso e usufruir dos maravilhosos e brilhantes frutos de nossas pesquisas.

Viva o ensino público de qualidade! Viva a ciência!

A cegueira também é isto, viver num mundo onde se tenha acabado a esperança.
(José Saramago em “Ensaio Sobre a Cegueira”, 1995, p. 204).

RESUMO

A floresta amazônica brasileira concentra um dos maiores estoques de biomassa e carbono no planeta, com total estimado de 150-200 Gt de carbono. Uma vez que as florestas atuam como sumidouros de carbono, o qual é estocado na biomassa florestal, também possuem importância na regulação climática do planeta. Portanto, estudos de quantificação de biomassa nessa floresta tropical são imprescindíveis para se buscar um maior entendimento nas questões ligadas às mudanças climáticas. Nesse sentido, ressaltam-se dois problemas relativos às estimativas de biomassa para o bioma Amazônia: 1. O uso de limitadas bases de dados de inventário florestal, com poucos registros de parcelas e indivíduos; 2. A aplicação de equações de biomassa genéricas para florestas tropicais, ou seja, não específicas para tipologias florestais. Além disso, dados relativos a inventários florestais no bioma Amazônia, os quais permitem as quantificações de biomassa e carbono, são escassos ou se encontram de maneira dispersa em diversas bases de dados, muitas vezes com acesso restrito, limitando a realização de estudos interdisciplinares. O objetivo do presente trabalho foi consolidar uma plataforma digital de livre acesso, com informações acerca da quantificação dos estoques de carbono e biomassa no bioma Amazônia, a partir de duas amplas bases de dados de inventários florestais (Projeto Paisagens Sustentáveis – EMBRAPA – e Projeto RADAMBRASIL), utilizando uma abordagem inédita, com aplicação de equações de biomassa específicas para duas tipologias florestais de ampla extensão territorial no bioma Amazônia: floresta densa e floresta aberta. Além disso, compararam-se os efeitos das equações de biomassa propostas por diferentes autores para essas fitofisionomias com equações genéricas para florestas tropicais, a fim de propor uma nova abordagem de espacialização para gerar mapas de biomassa específicos para as tipologias floresta densa e floresta aberta. Informações acerca das estimativas de biomassa e coordenadas geográficas de cada parcela foram integradas ao software JCarbon®, uma plataforma *open data*. Por fim, também foram comparadas estimativas de biomassa obtidas por meios de técnicas de regressão linear, aprendizado de máquina e dados LiDAR. Os resultados indicaram que a biomassa aérea de árvores com diâmetro ≥ 30 cm, para as duas tipologias florestais, é de 46,5 Gt, o que corresponde a 53% da biomassa total estimada para o bioma Amazônia (valor total, considerando todos os indivíduos vivos e todas as tipologias florestais ocorrentes), em comparação com dados publicados no relatório FRA 2020 (*Global Forest Resources Assessment*), publicado pela FAO (*Food and Agriculture Organization of the United Nations*). Trinta e dois mapas de distribuição de biomassa aérea e carbono aéreo de árvores foram gerados para as áreas de floresta densa e floresta aberta, proporcionando uma análise de sensibilidade espacial dos valores de biomassa e carbono preditos. Estimativas obtidas por meio de equações genéricas superestimaram em 4,6% e 33,2% os valores de biomassa obtidos por meio de equações específicas de floresta densa e floresta aberta, respectivamente. Houve um ganho de 11% no valor médio obtido de biomassa estimada pelas equações específicas. Conclui-se que o uso de equações de biomassa genéricas é inadequado para estimar a biomassa em ecossistemas como bioma Amazônia, caracterizado pela heterogeneidade fitoecológica. Dessa forma, para extensas bases de dados de inventário florestal, como é o caso do Projeto Paisagens Sustentáveis e do Projeto RADAMBRASIL, recomenda-se o uso de equações de biomassa específicas para as diferentes tipologias florestais. A partir da análise comparativa de estoques de biomassa obtidos por meio de equações de biomassa,

dados LiDAR e algoritmos de aprendizado de máquina, pode-se inferir que o uso de sistemas LiDAR tem elevado potencial não só para gerar mapas acurados da distribuição da biomassa, como também para a obtenção de valores confiáveis de biomassa acima do solo por unidade de área no bioma Amazônia. Ademais, equações de biomassa a partir de modelos tradicionais (regressão linear) e de modelos de aprendizado de máquina também se constituem em abordagens com bom desempenho preditivo da biomassa aérea de árvores no bioma Amazônia, recomendando-se, assim, a integração de dados de sistemas LiDAR com dados de inventários florestais. Por fim, a integração da base de dados do presente estudo com o software JCarbon[®] foi bem-sucedida, constituindo uma fonte de consulta espacial inédita (online-webgis e *open data*) de estoques de biomassa em grande número de parcelas no bioma Amazônia.

Palavras-chave: Floresta amazônica, biomassa acima do solo, dados abertos, estoques de biomassa, estoques de carbono, mudanças climáticas.

ABSTRACT

The Brazilian Amazon rainforest is one of the largest biomass and carbon sources on the planet, with a total estimated stock of around 150-200 Gt C. Given its importance as a carbon sink, biomass quantification studies in this area are essential to obtain a better understanding of climate change-related issues. Therefore, this study highlights two problems related to biomass estimates of the Amazon biome. First, the limited availability of forest inventory databases, with a limited sample size. Second, the application of generic allometric equations, i.e., non-forest type-specific equations, unsuitable to specific forest types. Furthermore, it is known that data on forest inventories in Brazil, mainly in the Brazilian Amazon, which allow the quantification of biomass and carbon, are scarce or are dispersed in several databases, often with restricted access, limiting the performance of interdisciplinary studies. This study aimed to estimate biomass and carbon storage from two large datasets of forest survey (Paisagens Sustentáveis Project and RADAMBRASIL Project), utilizing forest type-specific allometric equations for two predominant forest types in the Amazon biome: dense forests and open forests. Additionally, the dense and open forest equation effects were compared to establish a new spatialization approach to generate specific tree biomass maps for these forest types. Information about the biomass estimates and geographical coordinates of each plot were integrated to the JCarbon[®] software, an open data platform. Also, biomass estimates obtained by traditional methods (classical linear regression) machine learning and LiDAR data were also compared. The results indicated that the combined aboveground tree biomass of dense and open forest types, for trees with diameter ≥ 30 cm, was 46.5 Gt, or 53% of the biome's biomass (total value considering all living trees and forest types), compared to data published in the FRA 2020 report (Global Forest Resources Assessment), published by FAO (Food and Agriculture Organization of the United Nations). Thirty-two refined biomass maps were generated for dense and open forest areas, providing a novel spatial sensitivity analysis of the predicted biomass and carbon values predicted. Biomass estimates obtained utilizing the generic equations were overestimated by 4.6% and 33.2% compared to those obtained utilizing the specific equations for dense and open forests, respectively. Moreover, there was a gain of approximately 11% in the average biomass value obtained by the forest type-specific equations. It was concluded that only large-scale forest inventories databases may provide reliable biomass and carbon estimation, and forest type-specific equations should be utilized to estimate the Amazon biome's biomass, which is an environment characterized by phytoecological heterogeneity. Thus, for extensive forest inventory databases, such as the Paisagens Sustentáveis Project and the RADAMBRASIL Project, the use of specific allometric equations for different forest types is recommended. From the comparative analysis of biomass stocks obtained using allometric equations, LiDAR data and machine learning algorithms, it can be inferred that the use of LiDAR systems has high potential not only to generate accurate maps of the distribution of biomass, but, also, to obtain reliable values of aboveground biomass per unit area in the Amazon biome. In addition, biomass equations from traditional models (linear regression) and machine learning models provides a good predictive performance of aerial biomass estimates in the Amazon biome, thus indicating the integration of forest inventory data with LiDAR systems data. Finally, the integration of the database of the present study with the JCarbon[®] software was successful, constituting an unprecedented source of spatial data (online-webgis and

open data) of biomass stocks in a large number of inventory plots in the Amazon biome.

Keywords: Amazon rainforest, aboveground biomass, open data, biomass storage; carbon storage, climate change.

LISTA DE FIGURAS

FIGURA 1 – FATORES QUE INFLUENCIAM NA ALOCAÇÃO DE CARBONO NOS DIFERENTES COMPARTIMENTOS DAS PLANTAS.....	32
FIGURA 2 – PROPORÇÃO E DISTRIBUIÇÃO DA ÁREA FLORESTAL GLOBAL POR DOMÍNIO CLIMÁTICO.....	33
FIGURA 3 – DISTRIBUIÇÃO DOS ESTOQUES DE BIOMASSA ACIMA DO SOLO EM FLORESTAS TROPICAIS, EM Mg ha ⁻¹	35
FIGURA 4 – TENDÊNCIAS NA MUDANÇA DE BIOMASSA LÍQUIDA ACIMA DO SOLO (A), DA PRODUTIVIDADE (B) E DA EM MORTALIDADE DE BIOMASSA (C) EM 321 PARCELAS ESTUDADAS.	36
FIGURA 5 – EXEMPLO DE APLICAÇÃO DE ALGORITMO SUPERVISIONADO DE CLASSIFICAÇÃO NA DISTINÇÃO DO PESO (EIXO X) E ALTURA (EIXO Y) DE HOMENS E MULHERES.....	51
FIGURA 6 – EXEMPLO DE RELAÇÃO LINEAR: HORAS DE ESTUDO (EIXO X) E NOTAS DE ESTUDANTES EM UMA PROVA (EIXO Y).....	52
FIGURA 7 – DIFERENÇA ENTRE ALGORITMOS DE APRENDIZADO NÃO SUPERVISIONADO (A) E SUPERVISIONADO (B) PARA DADOS DE PESO (EIXO X) E ALTURA (EIXO Y) DE HOMENS E MULHERES.	54
FIGURA 8 – ETAPAS DO PROCESSO DE KDD.....	56
FIGURA 9 – VIZINHO MAIS PRÓXIMO DO CLASSIFICADOR BASEADO EM INSTÂNCIAS.....	58
FIGURA 10 – ESTRUTURA DAS CAMADAS EM REDES NEURAIS ARTIFICIAIS, COM CAMADA DE ENTRADA (INPUT LAYER), CAMADA OCULTA (HIDDEN LAYER) E CAMADA DE SAÍDA (OUTPUT LAYER).	60
FIGURA 11 – ESTRUTURA DE UM NEURÔNIO ARTIFICIAL, COM VALORES DE ENTRADA, PESOS, FUNÇÃO MATEMÁTICA DE ATIVAÇÃO (f_a) E SAÍDAS APÓS O TREINAMENTO DA REDE.	61
FIGURA 12 – ESTRUTURA DE MÁQUINA DE VETORES DE SUPORTE, SENDO A. MARGENS DAS RETAS QUE DEFINEM O HIPERPLANO; B. HIPERPLANO PARA CLASSIFICAÇÃO DE DADOS LINEARES EM DUAS DIMENSÕES.....	64
FIGURA 13 – ESTRUTURA DE UMA ÁRVORE DE REGRESSÃO.	66

FIGURA 14 – EXTENSÃO TERRITORIAL DO BIOMA AMAZÔNICO BRASILEIRO.	72
FIGURA 15 – LOCALIZAÇÃO DAS PARCELAS DO PROJETO RADAMBRASIL, EM QUATRO ESTADOS DO BIOMA AMAZÔNIA.	75
FIGURA 16 – LOCALIZAÇÃO DAS PARCELAS DO PROJETO RADAMBRASIL, EM 9 ESTADOS QUE COMPÕEM O BIOMA AMAZÔNIA, NA FLORESTA AMAZÔNICA BRASILEIRA.	79
FIGURA 17 – PROCEDIMENTO DE REAMOSTRAGEM BOOTSTRAP, APLICADA AOS DADOS DE INVENTÁRIO FLORESTAL DO PROJETO RADAMBRASIL E DO PROJETO PAISAGENS SUSTENTÁVEIS NO BIOMA AMAZÔNIA.	88
FIGURA 18 – DISTRIBUIÇÃO DIAMÉTRICA DE ÁRVORES EM PARCELAS NO BIOMA AMAZÔNIA, PARA AS TIPOLOGIAS FLORESTA OMBRÓFILA Densa – 164 PARCELAS - (A) E FLORESTA OMBRÓFILA ABERTA – 38 PARCELAS - (B), A PARTIR DOS DADOS DE INVENTÁRIO FLORESTAL DO PROJETO PAISAGENS SUSTENTÁVEIS, EMBRAPA. LINHA PONTILHADA NA VERTICAL REPRESENTA A MÉDIA ARITMÉTICA.	95
FIGURA 19 – COMPARAÇÃO ENTRE OS RESULTADOS OBTIDOS POR CADA EQUAÇÃO ALOMÉTRICA TESTADA, NAS ESTIMATIVAS DOS ESTOQUES DE BIOMASSA EM FLORESTA Densa. DADOS ORIUNDOS DO PROJETO PAISAGENS SUSTENTÁVEIS, EMBRAPA, NO BIOMA AMAZÔNIA.	102
FIGURA 20 – COMPARAÇÃO ENTRE OS RESULTADOS OBTIDOS POR CADA EQUAÇÃO ALOMÉTRICA TESTADA, NAS ESTIMATIVAS DOS ESTOQUES DE BIOMASSA EM FLORESTA ABERTA. DADOS ORIUNDOS DO PROJETO PAISAGENS SUSTENTÁVEIS, EMBRAPA, NO BIOMA AMAZÔNIA.	104
FIGURA 21 – DISTRIBUIÇÃO DIAMÉTRICA DE ÁRVORES EM PARCELAS NO BIOMA AMAZÔNIA, PARA AS TIPOLOGIAS FLORESTA OMBRÓFILA Densa – 1.158 PARCELAS - (A) E FLORESTA OMBRÓFILA ABERTA – 854 PARCELAS - (B), A PARTIR DOS DADOS DE INVENTÁRIO FLORESTAL DO PROJETO RADAMBRASIL. LINHA PONTILHADA NA VERTICAL REPRESENTA A MÉDIA ARITMÉTICA.	106

FIGURA 22 – DISTRIBUIÇÃO DA BIOMASSA POR HECTARE PELO NÚMERO DE REAMOSTRAS BOOTSTRAP, PARA CADA EQUAÇÃO ALOMÉTRICA DE FLORESTA Densa TESTADA. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA. LINHA PONTILHADA NA VERTICAL REPRESENTA A MÉDIA DAS REAMOSTRAGENS BOOTSTRAPP PARA CADA EQUAÇÃO.....	109
FIGURA 23 – DISTRIBUIÇÃO DA BIOMASSA POR HECTARE PELO NÚMERO DE REAMOSTRAS BOOTSTRAP, PARA CADA EQUAÇÃO ALOMÉTRICA DE FLORESTA ABERTA TESTADA. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA. LINHA PONTILHADA NA VERTICAL REPRESENTA A MÉDIA DAS REAMOSTRAGENS BOOTSTRAPP PARA CADA EQUAÇÃO.....	110
FIGURA 24 – COMPARAÇÃO ENTRE OS RESULTADOS OBTIDOS POR CADA EQUAÇÃO ALOMÉTRICA TESTADA, NAS ESTIMATIVAS DOS ESTOQUES DE BIOMASSA EM FLORESTA Densa. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA.	116
FIGURA 25 – COMPARAÇÃO ENTRE OS RESULTADOS OBTIDOS POR CADA EQUAÇÃO ALOMÉTRICA TESTADA, NAS ESTIMATIVAS DOS ESTOQUES DE BIOMASSA EM FLORESTA ABERTA. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA.	117
FIGURA 26 – MAPAS DE BIOMASSA FLORESTAL ACIMA DO SOLO (BAS), PARA FLORESTA Densa E FLORESTA ABERTA NO BIOMA AMAZÔNICO BRASILEIRO, A PARTIR DE DADOS DE INVENTÁRIO FLORESTAL DO PROJETO RADAMBRASIL, PARA ÁRVORES COM DAP ≥ 30 cm: A. Chambers et al. (2001) e Nogueira et al. (2008) Equação 1; B. Higuchi et al. (1998) e Nogueira et al. (2008) Equação 1; C. Silva (2007) e Nogueira et al. (2008) Equação 1; D. Brown (1997) Equação 1; E. Chambers et al. (2001) e Nogueira et al. (2008) Equação 2; F. Higuchi et al. (1998) e Nogueira et al. (2008) Equação 2; G. Silva (2007) e Nogueira et al. (2008) Equação 2; H. Brown (1997) Equação 2.	120

FIGURA 27 – MAPAS DE BIOMASSA FLORESTAL ACIMA DO SOLO (BAS), PARA FLORESTA Densa E FLORESTA ABERTA NO BIOMA AMAZÔNICO BRASILEIRO, A PARTIR DE DADOS DE INVENTÁRIO FLORESTAL DO PROJETO RADAMBRASIL, COM CÁLCULO CONSIDERANDO FATOR DE EXPANSÃO PARA INCLUSÃO DE ÁRVORES COM $10 \leq \text{DAP} < 30 \text{ cm}$: A. Chambers et al. (2001) e Nogueira et al. (2008) Equação 1; B. Higuchi et al. (1998) e Nogueira et al. (2008) Equação 1; C. Silva (2007) e Nogueira et al. (2008) Equação 1; D. Brown (1997) Equação 1; E. Chambers et al. (2001) e Nogueira et al. (2008) Equação 2; F. Higuchi et al. (1998) e Nogueira et al. (2008) Equação 2; G. Silva (2007) e Nogueira et al. (2008) Equação 2; H. Brown (1997) Equação 2. 122

FIGURA 28 – MAPAS DE CARBONO FLORESTAL ACIMA DO SOLO, PARA FLORESTA Densa E FLORESTA ABERTA NO BIOMA AMAZÔNICO BRASILEIRO, A PARTIR DE DADOS DE INVENTÁRIO FLORESTAL DO PROJETO RADAMBRASIL, PARA ÁRVORES COM $\text{DAP} \geq 30 \text{ cm}$: A. Chambers et al. (2001) e Nogueira et al. (2008) Equação 1; B. Higuchi et al. (1998) e Nogueira et al. (2008) Equação 1; C. Silva (2007) e Nogueira et al. (2008) Equação 1; D. Brown (1997) Equação 1; E. Chambers et al. (2001) e Nogueira et al. (2008) Equação 2; F. Higuchi et al. (1998) e Nogueira et al. (2008) Equação 2; G. Silva (2007) e Nogueira et al. (2008) Equação 2; H. Brown (1997) Equação 2. 124

FIGURA 29 – MAPAS DE CARBONO FLORESTAL ACIMA DO SOLO, PARA FLORESTA Densa E FLORESTA ABERTA NO BIOMA AMAZÔNICO BRASILEIRO, A PARTIR DE DADOS DE INVENTÁRIO FLORESTAL DO PROJETO RADAMBRASIL, COM CÁLCULO CONSIDERANDO FATOR DE EXPANSÃO PARA INCLUSÃO DE ÁRVORES COM $10 \leq \text{DAP} < 30 \text{ cm}$: A. Chambers et al. (2001) e Nogueira et al. (2008) Equação 1; B. Higuchi et al. (1998) e Nogueira et al. (2008) Equação 1; C. Silva (2007) e Nogueira et al. (2008) Equação 1; D. Brown (1997) Equação 1; E. Chambers et al. (2001) e Nogueira et al. (2008) Equação 2; F. Higuchi et al. (1998) e Nogueira et al. (2008) Equação 2; G. Silva (2007) e Nogueira et al. (2008) Equação 2; H. Brown (1997) Equação 2. 126

FIGURA 30 – TELA INICIAL DO SOFTWARE JCARBON®, COM INDICAÇÃO DOS LOCAIS (PONTOS EM VERMELHO) DAS PARCELAS DE INVENTÁRIO FLORESTAL NO BIOMA AMAZÔNIA.	132
FIGURA 31 – DISTRIBUIÇÃO DIAMÉTRICA DAS ÁRVORES NA ÁREA DE ESTUDO. LOCALIDADE: FAZENDA CAUAXI, PARAGOMINAS, PARÁ. DADOS EXTRAÍDOS DO PROJETO PAISAGENS SUSTENTÁVEIS DA EMBRAPA. LINHA PONTILHADA NA VERTICAL REPRESENTA A MÉDIA ARITMÉTICA.	134
FIGURA 32 – DISTRIBUIÇÃO DAS ALTURAS DAS ÁRVORES NA ÁREA DE ESTUDO. LOCALIDADE: FAZENDA CAUAXI, PARAGOMINAS, PARÁ. DADOS EXTRAÍDOS DO PROJETO PAISAGENS SUSTENTÁVEIS DA EMBRAPA. LINHA PONTILHADA NA VERTICAL REPRESENTA A MÉDIA ARITMÉTICA	135
FIGURA 33 – RELAÇÃO ENTRE OS DIÂMETROS E AS ALTURAS DAS ÁRVORES NA ÁREA DE ESTUDO. LOCALIDADE: FAZENDA CAUAXI, PARAGOMINAS, PARÁ. DADOS EXTRAÍDOS DO PROJETO PAISAGENS SUSTENTÁVEIS DA EMBRAPA.	136
FIGURA 34 – COMPARAÇÕES DE ESTOQUES DE BIOMASSA POR PARCELA. A. EQUAÇÃO PANTROPICAL E D'OLIVEIRA ET AL. (2012); B. EQUAÇÃO ANN E D'OLIVEIRA ET AL. (2012); C. EQUAÇÃO RANDOM FOREST E D'OLIVEIRA ET AL. (2012).	139
FIGURA 35 – COMPARAÇÕES DE ESTOQUES DE BIOMASSA POR PARCELA. A. EQUAÇÃO PANTROPICAL E EQUAÇÃO ANN; B. EQUAÇÃO PANTROPICAL E EQUAÇÃO RANDOM FOREST; C. EQUAÇÃO RANDOM FOREST E D'OLIVEIRA ET AL. (2012).	141
FIGURA 37 - CONSIDERAÇÕES FINAIS DA TESE: IMPACTOS DA PESQUISA.	150

LISTA DE TABELAS

TABELA 1 – ESTOQUES DE BIOMASSA E CARBONO ACIMA DO SOLO NOS BIOMAS BRASILEIROS.	38
TABELA 2 – ESTIMATIVAS DE BIOMASSA ACIMA DO SOLO REPORTADAS NA LITERATURA, PARA A AMAZÔNIA BRASILEIRA E FLORESTAS TROPICAIS.....	40
TABELA 3 – EXEMPLOS DE TAREFAS QUE PODEM SER CLASSIFICADAS COMO MINERAÇÃO DE DADOS VERSUS TAREFAS QUE NÃO PODEM SER CLASSIFICADAS COMO MINERAÇÃO DE DADOS.	57
TABELA 4 – FÓRMULAS DOS QUATRO TIPOS DE DISTÂNCIAS APLICADAS NO CÁLCULO DAS DISTÂNCIAS ENTRE VETORES.	59
TABELA 5 – EXEMPLOS DE FONTES DE DADOS ABERTOS (<i>OPEN DATA</i>).....	69
TABELA 6 – DETALHAMENTO DOS LOCAIS E Nº DE INDIVÍDUOS EXTRAÍDOS DA BASE DE DADOS DO PROJETO PAISAGENS SUSTENTÁVEIS....	74
TABELA 7 – CLASSES DIAMÉTRICAS E NÚMERO DE INDIVÍDUOS POR CLASSE, EM PARCELAS NO BIOMA AMAZÔNIA. DADOS DO PROJETO PAISAGENS SUSTENTÁVEIS, DA EMBRAPA.....	76
TABELA 8 – DETALHAMENTO DOS LOCAIS, PARCELAS E Nº DE INDIVÍDUOS EXTRAÍDOS DA BASE DE DADOS DO PROJETO RADAMBRASIL.	78
TABELA 9 – CLASSES DIAMÉTRICAS E NÚMERO DE INDIVÍDUOS POR CLASSE, EM PARCELAS NO BIOMA AMAZÔNIA. DADOS DO PROJETO RADAMBRASIL.	80
TABELA 10 – DETALHAMENTO DA BASE DE DADOS UTILIZADA PARA COMPARAÇÃO DAS ESTIMATIVAS DE BIOMASSA OBTIDAS POR MEIO DE EQUAÇÕES DE BIOMASSA, DADOS LIDAR E ALGORITMOS DE APRENDIZADO DE MÁQUINA. LOCALIDADE: FAZENDA CAUAXI, PARAGOMINAS, PARÁ. DADOS EXTRAÍDOS DO PROJETO PAISAGENS SUSTENTÁVEIS DA EMBRAPA.....	81
TABELA 11 – ESPECIFICAÇÕES TÉCNICAS DO SOBREVOO REALIZADO NA ÁREA DA FAZENDA CAUAXI PARA COLETA DAS NUVENS LIDAR. DADOS EXTRAÍDOS DO PROJETO PAISAGENS SUSTENTÁVEIS DA EMBRAPA.....	82

TABELA 12 – EQUAÇÕES DE BIOMASSA UTILIZADAS NAS ESTIMATIVAS DE BIOMASSA ACIMA DO SOLO (BAS).	86
TABELA 13 – EQUAÇÕES DE BIOMASSA AJUSTADAS POR BROWN (1997), PARA ESTIMAÇÃO DA BIOMASSA EM FLORESTAS TROPICAIS.....	87
TABELA 14 – ALGORITMOS DE APRENDIZADO DE MÁQUINA, EPECIFICADOS DE ACORDO COM A CONFIGURAÇÃO ÓTIMA DE HIPERPARÂMETROS.	91
TABELA 15 – DESCRIÇÃO DA BASE DE DADOS DO PROJETO PAISAGENS SUSTENTÁVEIS DA EMBRAPA, PARA A VARIÁVEL DIÂMETRO À ALTURA DO PEITO.....	94
TABELA 16 – ESTOQUES DE BIOMASSA, CARBONO E EMISSÕES DE CO _{2eq} em Mg ha ⁻¹ , ESTIMADOS A PARTIR DAS EQUAÇÕES DE HIGUCHI ET AL. (1998), CHAMBERS ET AL. (2001) E SILVA (2007), PARA PARCELAS EM FLORESTA OMBRÓFILA DENSE. DADOS ORIUNDOS DO PROJETO PAISAGENS SUSTENTÁVEIS, EMBRAPA, NO BIOMA AMAZÔNIA.	98
TABELA 17 – ESTOQUES DE BIOMASSA E CARBONO, E EMISSÕES DE CO _{2EQ} , EM Mg ha ⁻¹ , ESTIMADOS A PARTIR DAS EQUAÇÕES DE NOGUEIRA ET AL. (2008) EQUAÇÃO 1 E NOGUEIRA ET AL. (2008) EQUAÇÃO 2, PARA PARCELAS EM FLORESTA OMBRÓFILA ABERTA. DADOS ORIUNDOS DO PROJETO PAISAGENS SUSTENTÁVEIS, EMBRAPA, NO BIOMA AMAZÔNIA.....	100
TABELA 18 – DESCRIÇÃO DA BASE DE DADOS DO PROJETO PAISAGENS SUSTENTÁVEIS DA EMBRAPA, PARA A VARIÁVEL DIÂMETRO À ALTURA DO PEITO.....	105
TABELA 19 – ESTOQUES DE BIOMASSA E CARBONO, E EMISSÕES DE CO _{2eq} (Mg ha ⁻¹), ESTIMADOS A PARTIR DAS EQUAÇÕES DE HIGUCHI ET AL. (1998), CHAMBERS ET AL. (2001) E SILVA (2007), PARA 1.158 PARCELAS EM FLORESTA OMBRÓFILA DENSE. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA.	112
TABELA 20 – ESTOQUES DE BIOMASSA E CARBONO, E EMISSÕES DE CO _{2eq} (Mg ha ⁻¹), ESTIMADOS A PARTIR DAS EQUAÇÕES DE NOGUEIRA ET AL. (2008) EQUAÇÃO 1 E NOGUEIRA ET AL. (2008) EQUAÇÃO	

2, PARA 854 PARCELAS EM FLORESTA OMBRÓFILA ABERTA. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA.	114
TABELA 21 – BIOMASSA ACIMA DO SOLO (BAS) ESTIMADA PARA O BIOMA AMAZÔNIA, EM GIGATONELADAS (Gt), A PARTIR DE EQUAÇÕES DE BIOMASSA DE FLORESTA Densa E FLORESTA ABERTA E EQUAÇÕES GENÉRICAS PARA FLORESTAS TROPICAIS.....	127
TABELA 22 – COMPARAÇÕES DE ESTIMATIVAS DE BIOMASSA ACIMA DO SOLO (BAS) PARA A AMAZÔNIA BRASILEIRA E PARA FLORESTAS TROPICAIS, REPORTADAS NA LITERATURA.	130
TABELA 23 – DESCRIÇÃO DA BASE DE DADOS. LOCALIDADE: FAZENDA CAUAXI, PARAGOMINAS, PARÁ. DADOS EXTRAÍDOS DO PROJETO PAISAGENS SUSTENTÁVEIS DA EMBRAPA.	133
TABELA 24 – RESULTADOS DAS ESTIMATIVAS DE BIOMASSA ACIMA DO SOLO (BAS) POR PARCELA, EM $Mg\ ha^{-1}$, OBTIDAS A PARTIR DO MODELO ALOMÉTRICO DE CHAVE et al. (2014), MODELOS ANN E RANDOM FOREST E DA EQUAÇÃO DE D'OLIVEIRA ET AL. (2012).	137
TABELA 25 – RESULTADOS DAS ESTIMATIVAS DE BIOMASSA ACIMA DO SOLO (BAS) POR PARCELA, EM $Mg\ ha^{-1}$, OBTIDAS A PARTIR DE ALGORITMOS DE APRENDIZADO DE MÁQUINA COM MELHORES DESEMPENHOS, BASEADO NO TRABALHO DE SOUZA (2020).	146
TABELA 26 – RECOMENDAÇÕES FUTURAS ALINHADAS COM OS OBJETIVOS DA TESE.....	153

LISTA DE ABREVIATURAS OU SIGLAS

AM	- Aprendizado de Máquina
ANN	- <i>Artificial Neural Network</i>
BAS	- Biomassa Acima do Solo
COP	- Conferência das Partes
DAP	- Diâmetro à altura do peito (1,30 m)
FAO	- <i>Food and Agriculture Organization</i>
GIS	- <i>Geographic Information System</i>
IA	- Inteligência artificial
IDE	- <i>Integrated Development Environment</i>
INDE	- Infraestrutura Nacional de Dados Espaciais
IBGE	- Instituto Brasileiro de Geografia e Estatística
IPCC	- <i>Intergovernmental Panel on Climate Change</i> (Painel Intergovernamental sobre Mudanças Climáticas)
KDD	- <i>Knowledge Discovery in Database</i> (Descoberta de Conhecimento em Bases de Dados)
KNN	- <i>k</i> -Nearest Neighbor (<i>k</i> Vizinho Mais Próximo)
LiDAR	- <i>Light Detection and Ranging</i>
MD	- Mineração de Dados
ONU	- Organização das Nações Unidas
REDD+	- Redução de Emissões provenientes de Desmatamento e Degradação Florestal
RNA	- Redes Neurais Artificiais
SIG	- Sistema de Informação Geográfica
SGB	- Stochastic Gradient Boosting (Gradiente Boosting Estocástico)
SVM	- <i>Support Vector Machine</i> (Máquinas de Vetores de Suporte)
SVR	- <i>Support Vector Regression</i> (Vetores de Suporte para Regressão)
UFPR	- Universidade Federal do Paraná
UNFCCC	- United Nations Framework Convention on Climate Change (Convenção-Quadro das Nações Unidas sobre a Mudança do Clima)

SUMÁRIO

1 INTRODUÇÃO	26
1.1 HIPÓTESES	30
1.2 OBJETIVOS	30
1.2.1 Objetivo geral	30
1.2.2 Objetivos específicos.....	30
2 REVISÃO DE LITERATURA	31
2.1 ESTOQUES DE BIOMASSA E CARBONO NAS FLORESTAS	31
2.2 ESTOQUES DE BIOMASSA E CARBONO EM FLORESTAS TROPICAIS.....	33
2.3 ESTOQUES DE BIOMASSA E CARBONO NO BRASIL E NA AMAZÔNIA	37
2.3.1 Brasil.....	37
2.3.2 Amazônia.....	39
2.4 MÉTODOS TRADICIONAIS DE QUANTIFICAÇÃO DE BIOMASSA	41
2.5 NOVAS TÉCNICAS PARA QUANTIFICAÇÃO DE BIOMASSA FLORESTAL	42
2.5.1 Geotecnologias.....	43
2.5.1.1 Imagens de satélite	43
2.5.1.2 LiDAR.....	44
2.5.1.3 Satélites Sentinel.....	46
2.5.2 Algoritmos de aprendizado de máquina	46
2.6 INTELIGÊNCIA ARTIFICIAL (IA)	48
2.6.1 Aprendizado de máquina (AM)	50
2.6.1.1 Aprendizado supervisionado	50
2.6.1.2 Aprendizado não supervisionado	53
2.6.1.3 Processo de KDD (Knowledge Discovery in Databases)	55
2.6.1.4 Mineração de Dados	56
2.6.1.5 Principais algoritmos de aprendizado de máquina aplicados nas ciências florestais.....	57
a) KNN (<i>k-Nearest Neighbors</i>).....	57
b) Redes Neurais Artificiais.....	60
c) Support Vector Machine (SVM) e Support Vector Regression (SVR).....	63
d) Árvores de Regressão e Random Forest	65
2.7 DADOS ABERTOS	67
3 MATERIAL E MÉTODOS	72
3.1 BIOMA AMAZÔNIA	72

3.2 BASES DE DADOS.....	73
3.2.1 Projeto Paisagens Sustentáveis (EMBRAPA)	73
3.2.2 Projeto RADAMBRASIL	76
3.2.3 Projeto Paisagens Sustentáveis (EMBRAPA): base de dados para comparação de estoques de biomassa obtidos por meio de equações de biomassa, dados LiDAR e algoritmos de aprendizado de máquina	80
3.3 PROCESSO DE KDD.....	82
3.4 EQUAÇÕES DE BIOMASSA	85
3.4.1 MÉTODO BOOTSTRAP.....	88
3.5 COMPARAÇÃO DE ESTOQUES DE BIOMASSA OBTIDOS POR MEIO DE EQUAÇÕES DE BIOMASSA, DADOS LIDAR E ALGORITMOS DE APRENDIZADO DE MÁQUINA.....	89
3.6 INTEGRAÇÃO COM O SOFTWARE JCARBON®	92
3.7 MAPAS DE BIOMASSA E CARBONO.....	92
4 RESULTADOS E DISCUSSÃO	94
4.1 ESTIMATIVAS DE BIOMASSA E CARBONO PARA DADOS DO PROJETO PAISAGENS SUSTENTÁVEIS (EMBRAPA).....	94
4.1.1 Distribuição diamétrica	94
4.1.2 Estoques de biomassa e carbono e emissões de CO _{2eq}	95
4.1.3 Comparações entre as estimativas obtidas por meio das equações de biomassa	101
4.2 ESTIMATIVAS DE BIOMASSA E CARBONO PARA DADOS DO PROJETO RADAMBRASIL.....	105
4.2.1 Distribuição diamétrica	105
4.2.2 Estoques de biomassa e carbono e emissões de CO _{2eq}	107
4.2.3 Comparações entre as estimativas obtidas por meio das equações de biomassa	115
4.2.4 Mapas de biomassa e carbono	118
4.2.5.1 Comparações de estoques de biomassa por hectare.....	129
4.3 INTEGRAÇÃO COM O SOFTWARE JCARBON®	132
4.4 COMPARAÇÕES DE ESTOQUES DE BIOMASSA OBTIDOS POR MEIO DE EQUAÇÕES DE BIOMASSA, DADOS LIDAR E ALGORITMOS DE APRENDIZADO DE MÁQUINA.....	133
4.4.1 Análise descritiva dos dados	133

4.4.2 Estimativas de biomassa por meio do aplicativo web MLMBio	136
4.4.3 Estimativas de biomassa obtidas por meio de outros algoritmos de aprendizado de máquina.....	145
5 CONCLUSÕES	148
6 CONSIDERAÇÕES FINAIS	150
7 RECOMENDAÇÕES FUTURAS.....	153
REFERÊNCIAS.....	156
APÊNDICE 1 – DENSIDADE DA MADEIRA POR ESPÉCIE, APLICADA AO CONJUNTO DE DADOS DA SEÇÃO 4.4.....	170
APÊNDICE 2 – INTERVALOS DE CONFIANÇA DE ESTOQUES DE BIOMASSA POR CLASSE DIAMÉTRICA (MG HA⁻¹), PARA CADA EQUAÇÃO APLICADA A PARCELAS DE FLORESTA Densa NA AMAZÔNIA BRASILEIRA. DADOS ORIUNDOS DO PROJETO PAISAGENS SUSTENTÁVEIS, DA EMBRAPA, PARA O BIOMA AMAZÔNIA.	175
APÊNDICE 3 – INTERVALOS DE CONFIANÇA DE ESTOQUES DE BIOMASSA POR CLASSE DIAMÉTRICA (MG HA⁻¹), PARA CADA EQUAÇÃO APLICADA A PARCELAS DE FLORESTA ABERTA NA AMAZÔNIA BRASILEIRA. DADOS ORIUNDOS DO PROJETO PAISAGENS SUSTENTÁVEIS, DA EMBRAPA, PARA O BIOMA AMAZÔNIA.	177
APÊNDICE 4 – ESTOQUES DE BIOMASSA, CARBONO E EMISSÕES DE CO₂EQ (MG), ESTIMADOS A PARTIR DAS EQUAÇÕES DE HIGUCHI ET AL. (1998), CHAMBERS ET AL. (2001) E SILVA (2007), PARA 1.158 PARCELAS DE FLORESTA Densa NA AMAZÔNIA BRASILEIRA. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA.....	178
APÊNDICE 5 – ESTOQUES DE BIOMASSA, CARBONO E EMISSÕES DE CO₂EQ (MG), ESTIMADOS A PARTIR DAS EQUAÇÕES DE NOGUEIRA ET AL. (2008) EQUAÇÃO 1 E NOGUEIRA ET AL. (2008) EQUAÇÃO 2, PARA 854 PARCELAS DE FLORESTA ABERTA NA AMAZÔNIA BRASILEIRA. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA.....	180
APÊNDICE 6 – INTERVALOS DE CONFIANÇA DE ESTOQUES DE BIOMASSA POR CLASSE DIAMÉTRICA (MG HA⁻¹), PARA CADA EQUAÇÃO APLICADA A PARCELAS DE FLORESTA Densa NA AMAZÔNIA BRASILEIRA. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA.	181

**APÊNDICE 7 – INTERVALOS DE CONFIANÇA DE ESTOQUES DE BIOMASSA
POR CLASSE DIAMÉTRICA (MG HA⁻¹), PARA CADA EQUAÇÃO APLICADA A
PARCELAS DE FLORESTA ABERTA NA AMAZÔNIA BRASILEIRA. DADOS
ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA.....183**

1 INTRODUÇÃO

As florestas desempenham um importante papel no ciclo global do carbono e na regulação do clima do planeta, uma vez que atuam como sumidouros de carbono, o qual é estocado na biomassa florestal (PAN et al., 2011; SILVEIRA et al., 2008). A partir da quantificação de biomassa em ecossistemas florestais, é possível estimar os estoques de carbono e a quantidade de CO₂ que é liberado à atmosfera mediante processos naturais (i.e. mortalidade; fotorrespiração) e antrópicos (i.e. desmatamento; queimadas) (FEARNSIDE, 1997a; HIGUCHI et al., 1998). Essas estimativas auxiliam a compreensão da dinâmica dos fluxos de carbono entre os ecossistemas terrestres e a atmosfera (CUTLER et al., 2012), bem como as funções das florestas no ciclo do carbono global (FAN et al., 1998).

Estudos como o de Sanquetta; Balbinot (2004) relatam o importante papel que as árvores exercem como sumidouros de carbono. Esses autores argumentam que as florestas, além de configurarem uma fonte alternativa renovável de energia, também podem contribuir decisivamente para reduzir os impactos ambientais do efeito estufa e de suas implicações nas mudanças climáticas.

A preocupação mundial com as alterações do clima tem levado representantes de diversos países a tomarem medidas por meio de acordos e tratados, no âmbito da Convenção-Quadro das Nações Unidas sobre a Mudança do Clima (UNFCCC, na sigla em inglês), como o Protocolo de Quioto e dos Acordos Globais de Clima. Além disso, periodicamente, são realizadas as Conferências do Clima da ONU (COPs), cujo objetivo é estabelecer novas metas e acordos entre os países, além de reportar o cumprimento de metas estabelecidas em anos anteriores.

Em ecossistemas tropicais, as estimativas de biomassa e carbono são obtidas por meio de métodos diretos ou indiretos (BROWN; GILLESPIE; LUGO, 1989), a partir de informações de levantamentos florestais. Entretanto, nos últimos anos, a combinação de técnicas tradicionais de inventário florestal e sensoriamento remoto tem sido amplamente difundida (LONGO et al., 2016; TEJADA et al., 2019). Essa integração é necessária devido à ampla extensão geográfica da floresta amazônica e dificuldades de acessibilidade em campo, bem como à variabilidade espacial natural da biomassa florestal (SAATCHI et al., 2011). Além disso, o uso de sensores remotos aprimoraram os métodos de amostragem terrestre, permitindo uma melhor avaliação dos recursos florestais em várias escalas (BREIDENBACH; ASTRUP, 2012). Uma

ferramenta alternativa e complementar às imagens de satélite que tem ganhado destaque nos últimos anos é a tecnologia LiDAR (*Light Detection and Ranging*). Sensores LiDAR emitem pulsos *laser* em um processo de escaneamento, possibilitando a determinação da distância entre o aparelho e os alvos e, conseqüentemente, permitindo fazer medições espaciais (ASNER et al., 2015).

As estimativas de biomassa em florestas tropicais apresentam um alto grau de incerteza associada, inerentes às medições em áreas territoriais extensas, como também a heterogeneidade da vegetação encontrados nesses ecossistemas (LONGO et al., 2016; NOGUEIRA et al., 2008). Com o intuito de reduzir esse grau de incerteza nas estimativas de biomassa, a elaboração de mapas acurados de distribuição da biomassa e carbono tem sido abordada por muitos autores (SAATCHI et al., 2011; OMETTO et al., 2014; AVITABILE et al., 2016; LONGO et al., 2016). Esses mapas resultam da combinação de dados de imagens de satélite, dados provenientes de LiDAR e informações de campo. Portanto, os inventários florestais ainda são uma relevante fonte de informações para a geração de estimativas acuradas de biomassa e carbono em ecossistemas florestais (ZHENG et al., 2007).

Entretanto, na Amazônia brasileira, dados de campo oriundos de inventários florestais ainda são escassos ou se encontram de maneira dispersa em diversas bases, muitas vezes com acesso restrito. Há uma incipiência de trabalhos recentes conduzidos por órgãos ou instituições públicas datados dos últimos 10 anos. Não obstante, esses dados são, geralmente, restritos a determinados órgãos governamentais ou institutos de pesquisa. Considerando que a floresta amazônica concentra os maiores estoques de biomassa e carbono do planeta (PHILLIPS et al., 2009; PAN et al., 2011; FELDPAUSCH et al., 2012), é importante o acesso livre aos dados de levantamentos florestais, imprescindíveis na difusão de estudos e pesquisas sobre a quantificação de biomassa e carbono florestal no ecossistema Amazônico.

A Agenda 21, documento final da Conferência das Nações Unidas para o Meio Ambiente e Desenvolvimento (Rio-92), abordou as dificuldades no acesso e utilização dos dados produzidos pelas instituições, entre elas, falta de padronização na coleta e disposição dos dados em sistemas divergentes. Essa preocupação impulsionou o estabelecimento de acordos de compartilhamento e a construção das Infraestruturas de Dados Espaciais (IDEs), abrangendo tecnologias, políticas e padrões para aquisição, processamento e distribuição de dados geoespaciais (IBGE, 2020b).

As IDEs seguem padrões preconizados pelo *Open Geospatial Consortium* (OGC) e hoje conta com mais de 500 membros (governos, universidades e setor privado) atuando no desenvolvimento e aprimoramento de *softwares* livres e outras tecnologias que facilitam o intercâmbio de dados. No Brasil, destaca-se a plataforma de Infraestrutura Nacional de Dados Espaciais (INDE - <https://inde.gov.br/>), coordenada pelo IBGE (Instituto Brasileiro de Geografia e Estatística). No exterior, o acesso aberto a dados científicos vem ganhando adeptos a partir de movimentos como o *Open Science* (Ciência Aberta), uma das frentes de atuação da *Open Knowledge International*. A organização foi criada em 2004 e conta com iniciativas em todo o mundo, inclusive no Brasil (OPEN KNOWLEDGE BRASIL, 2020).

Recentemente, o IBGE elaborou a plataforma online BDIA (Banco de Dados de Informações Ambientais), na qual constam dados de recursos naturais do território nacional brasileiro, produzidos ao longo dos últimos 20 anos (IBGE, 2020a). Na plataforma BDIA estão disponibilizados, gratuitamente, dados obtidos pelo Projeto RADAMBRASIL, no qual foi realizado o levantamento de recursos naturais brasileiros, nas décadas de 1970 e 1980, incluindo informações da vegetação para todos os biomas brasileiros.

Foram identificados dois problemas relativos às estimativas de biomassa no bioma Amazônia: 1. As bases de dados de inventário florestal existentes na Amazônia brasileira são limitadas, com poucos registros de parcelas e indivíduos; e 2. As equações de biomassa genéricas aplicadas às florestas tropicais são genéricas, ou seja, não específicas para tipologias florestais. Neste estudo, os termos “equações genéricas” e “equações específicas” foram utilizados com referência às tipologias florestais.

O objetivo deste trabalho foi consolidar uma plataforma digital de livre acesso, utilizando uma abordagem inédita com aplicação de equações de biomassa específicas para duas tipologias florestais de ampla extensão territorial no bioma Amazônia: floresta densa e floresta aberta. Além disso, comparar estimativas provenientes das equações específicas para as tipologias floresta densa e floresta aberta, com o intuito de propor uma nova abordagem de espacialização para gerar mapas de biomassa específicos para estas tipologias. Por fim, comparar as estimativas de biomassa obtidas por técnicas de regressão linear, aprendizado de máquina e dados LiDAR.

Duas amplas bases de dados de inventários florestais foram utilizadas: 1. Base de dados do Projeto Paisagens Sustentáveis, da EMBRAPA, com registro de 13.695 árvores ($DAP \geq 5$ cm) em 202 parcelas; 2. Base de dados do Projeto RADAMBRASIL, com registro de 114.231 árvores ($DAP \geq 30$ cm) em 2.012 parcelas.

1.1 HIPÓTESES

- Equações de biomassa específicas para tipologias florestais propiciam melhor performance para estimar os estoques de biomassa e carbono de árvores individuais no bioma Amazônia, em comparação com estimativas obtidas por meio de equações genéricas para florestas tropicais.
- Estimativas de biomassa obtidas por meio de equação com *input* de métricas LiDAR são mais acuradas para a predição de biomassa aérea de árvores bioma Amazônia que as equações obtidas por meios de técnicas de regressão linear e aprendizado de máquina.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Consolidar uma plataforma digital de livre acesso para estoques de carbono e biomassa no bioma Amazônia.

1.2.2 Objetivos específicos

- Quantificar os estoques de biomassa e carbono acima do solo em todas as parcelas analisadas;
- Integrar a base de dados ao *software* JCarbon®, com informações acerca das estimativas de biomassa e coordenadas geográficas de cada parcela;
- Avaliar a aplicação de equações de biomassa específicas de floresta densa e floresta aberta para estimar biomassa e carbono em duas tipologias florestais, de ampla extensão territorial no bioma Amazônia;
- Comparar os efeitos das equações específicas de floresta densa e floresta aberta, com o intuito de propor nova uma abordagem de espacialização para gerar mapas de biomassa específicos para estas tipologias florestais;
- Comparar estimativas de biomassa obtidas por meios de técnicas de regressão linear, aprendizado de máquina e dados LiDAR.

2 REVISÃO DE LITERATURA


2.1 ESTOQUES DE BIOMASSA E CARBONO NAS FLORESTAS

As árvores, ao realizarem trocas gasosas via fotossíntese, convertem energia solar em energia química por meio de reações envolvendo moléculas de carbono, as quais são obtidas na forma de CO₂ atmosférico, resultando na síntese de diversos compostos orgânicos (TAIZ; ZEIGER, 2004). Como consequência desses processos, grande parte do carbono presente na atmosfera é assimilado pelas árvores e estocado na forma de biomassa. Biomassa pode ser definida como a quantidade expressa em massa do material vegetal disponível em uma floresta (MARTINELLI et al., 1994). O termo biomassa florestal remete à biomassa existente na floresta ou apenas na sua fração arbórea, e, em se tratando de biomassa de origem vegetal, vem sendo empregado o termo fitomassa (SANQUETTA, 2002).

Os estudos de quantificação de biomassa florestal são imprescindíveis para se buscar um maior entendimento nas questões ligadas, entre outras, às áreas de manejo florestal e clima (HIGUCHI et al., 1998). No manejo florestal, a quantificação da biomassa também é relevante para dimensionar os estoques de macro e micronutrientes da vegetação - obtidos pelo produto da massa pelas concentrações de cada mineral - além de ser um indicativo das condições fitossanitárias de um ecossistema (SILVEIRA et al., 2008), do potencial de incêndio de uma floresta (quantificação de material combustível) (RATUCHNE et al., 2016), entre outras aplicações (FIGURA 1).

Em estudos climáticos, a biomassa é o principal meio para estimar os estoques de carbono, que, por sua vez, são utilizados para estimar a quantidade de CO₂ liberado na atmosfera mediante processos naturais (i.e. mortalidade e fotorrespiração) e antrópicos (i.e. desmatamento e queimadas) (FEARNSIDE, 1997a; HIGUCHI et al., 1998).

FIGURA 1 – FATORES QUE INFLUENCIAM NA ALOCAÇÃO DE CARBONO NOS DIFERENTES COMPARTIMENTOS DAS PLANTAS.



FONTE: Adaptado de NGEE-TROPICS (2020).

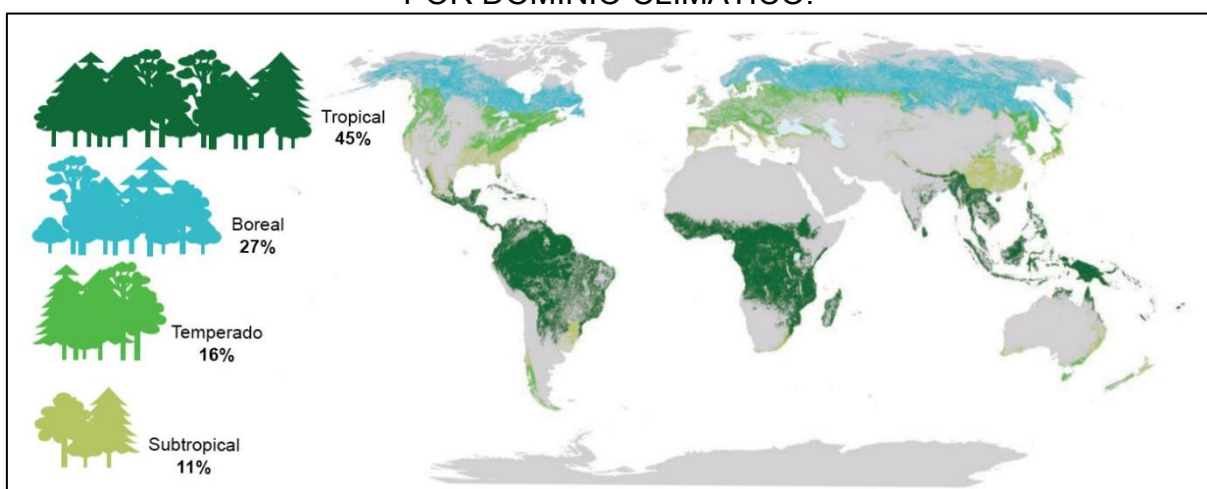
A quantificação da biomassa acima do solo em formações tropicais é de fundamental importância para a compreensão da dinâmica dos fluxos de carbono entre os ecossistemas terrestres e a atmosfera (CUTLER et al., 2012) e as funções das florestas no ciclo global do carbono (FAN et al., 1998). Além disso, estimativas precisas de biomassa nas florestas tropicais são essenciais para determinar os padrões geográficos dos estoques de carbono, as magnitudes dos fluxos devido à mudança do uso do solo, bem como para quantificar as emissões de carbono evitadas por meio de mecanismos como o REED+ (Redução das Emissões por Desmatamento e Degradação) (FELDPAUSCH et al., 2012).

De acordo com dados do último relatório FRA (*Global Forest Resources Assessment*), publicado pela FAO (*Food and Agriculture Organization of the United Nations*), as florestas do mundo estocam cerca de 606 gigatoneladas (Gt) de biomassa viva (acima e abaixo do solo) e 59 Gt de necromassa (FAO, 2020). O carbono total estoque em florestas diminuiu de 668 Gt em 1990 para 662 Gt em 2020.

Ainda de acordo com a FAO (2020), a biomassa total diminuiu desde 1990. Entretanto, o valor de biomassa por unidade de área aumentou. Considerando a compartimentação de biomassa, 44% dos estoques de carbono concentram-se na biomassa viva acima; 45% na matéria orgânica do solo; 6% na serapilheira; e 4% na necromassa.

As florestas cobrem cerca de um terço da superfície terrestre. Isso corresponde a uma área de 4 bilhões de hectares, sendo que cinco países concentram 54% da área florestal ao redor do globo (FAO, 2020). São estes: Rússia (815 milhões de ha = 20%); Brasil (497 milhões de ha = 12%); Canadá (347 milhões de ha = 9%); Estados Unidos (310 milhões de ha = 8%); e China (220 milhões de ha = 5%). Entretanto, o bioma floresta tropical tem a maior proporção de florestas do mundo (45%), seguido pelos biomas boreal (27%), temperado (16%) e subtropical (11%) (FIGURA 2). Portanto, as florestas tropicais concentram os maiores estoques de biomassa e carbono florestal do planeta Terra.

FIGURA 2 – PROPORÇÃO E DISTRIBUIÇÃO DA ÁREA FLORESTAL GLOBAL POR DOMÍNIO CLIMÁTICO.



FONTE: Adaptado de FAO (2020).

2.2 ESTOQUES DE BIOMASSA E CARBONO EM FLORESTAS TROPICAIS

As florestas tropicais cobrem cerca de 19,5 milhões de km² da superfície terrestre e são responsáveis por 34% da produtividade primária líquida global (NPP, na sigla em inglês) (BEER et al., 2010). Essas florestas são responsáveis, segundo

estimativas, por estocar cerca de 1,2 - 0,4 gigatonelada de carbono por ano¹ (Gt C.ano⁻¹), o que corresponde a cerca de dois terços da capacidade estoque de biomassa global (PAN et al., 2011).

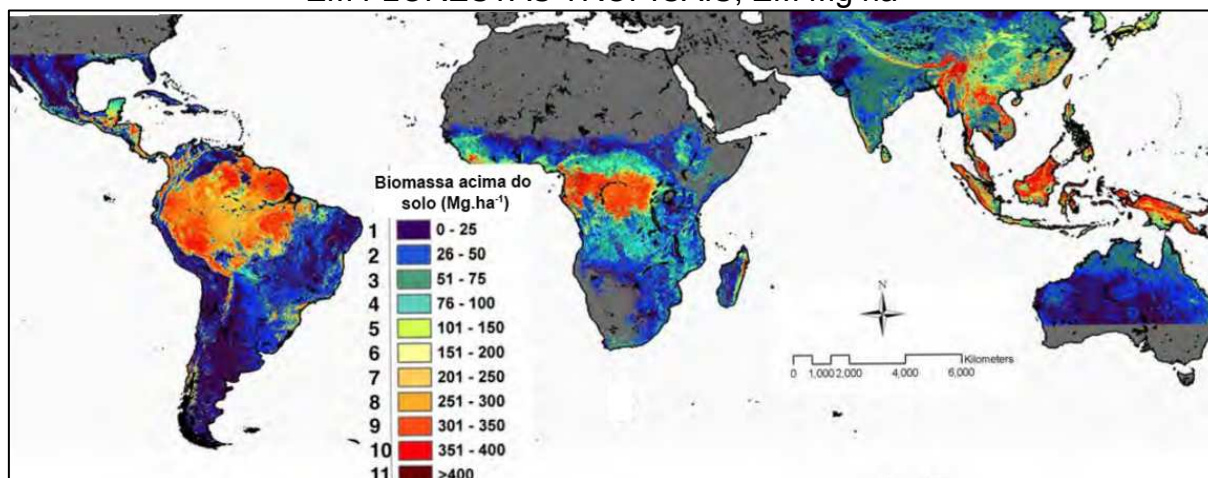
Estima-se que o estoque total de carbono acima do solo nas florestas do mundo é de 861 ± 66 Gt C, sendo que 43% estão estocados na biomassa viva (acima e abaixo do solo), o que corresponde a 363 ± 28 Gt C (PAN et al., 2011). Os mesmos autores encontraram que cerca de 32% do carbono está estocado em florestas boreais e 14% em florestas temperadas. Nesse contexto, as florestas tropicais são consideradas o maior sumidouro de carbono do planeta (BACCINI et al., 2012). De acordo com o FRA, o total de carbono estocado na biomassa das florestas do mundo é de cerca de 606 Gt C (FAO, 2020). Essas divergências nos valores dos estoques de carbono podem ser explicadas por diferenças de metodologia adotadas.

Cabe destacar que, nas estimativas de biomassa em florestas tropicais, há um alto grau de incerteza associada, inerentes às medições em áreas territoriais extensas, como também aos diferentes tipos de vegetação encontrados nesses ecossistemas (NOGUEIRA et al., 2008; LONGO et al., 2016). Com o intuito de reduzir esse grau de incerteza nas estimativas de biomassa, a elaboração de mapas pantropicais acurados de biomassa e carbono tem sido abordada por muitos autores (SAATCHI et al., 2011; OMETTO et al., 2014; AVITABILE et al., 2016; LONGO et al., 2016).

Estudos recentes apontam a notável concentração dos estoques de biomassa acima do solo nas regiões tropicais e neotropicais do globo, com destaque para a floresta amazônica e para as regiões tropicais da Ásia e da África. O valor médio de biomassa acima do solo na região tropical, a partir desses mapas pantropicais, é de 250-350 Mg ha⁻¹ (megagrama por hectare) (FIGURA 3).

¹ Gigatonelada (Gt) = 10^{15} gramas = 1 bilhão de toneladas.

FIGURA 3 – DISTRIBUIÇÃO DOS ESTOQUES DE BIOMASSA ACIMA DO SOLO EM FLORESTAS TROPICAIS, EM Mg ha^{-1}




FONTE: Adaptado de Saatchi et al. (2011).

Há controvérsias com relação à obtenção de estimativas confiáveis de estoques de carbono e biomassa em florestas tropicais, devido aos diferentes métodos utilizados e aos diferentes processos de amostragem pelos quais os dados são obtidos. Tais controvérsias reacendem o debate sobre a seguinte questão: as florestas tropicais são uma fonte ou um sumidouro de carbono? Por um lado, as florestas podem agir como sumidouros, por meio da absorção de carbono durante a fotossíntese pelas plantas que estocam o excesso na forma de biomassa (PHILLIPS et al., 1998; NOBRE, 2001; HIGUCHI et al., 2004). Porém, as florestas também podem ser fonte de carbono, devido à diminuição da produtividade florestal e aumento nas taxas de mortalidade, decorrentes do aumento da temperatura e da severidade das secas, causadas, potencialmente, pelos fenômenos climáticos El Niño e La Niña (CLARK, 2004; HIGUCHI et al., 2011) ou devido a atividades antrópicas, como desmatamento e queimadas (FEARNSIDE, 1997a).

Um relevante estudo recente a ser citado é o de Brien et al. (2015). Nesse estudo, os autores analisaram a evolução histórica da dinâmica de biomassa da floresta amazônica ao longo das últimas três décadas, com dados obtidos de 321 parcelas. Apesar de os resultados do estudo confirmarem que a floresta amazônica tem agido como um sumidouro de biomassa líquida, os autores também constataram que, a longo prazo, há uma tendência de que haja um decréscimo no acúmulo de carbono nessa floresta (FIGURA 4). Tal decréscimo seria uma consequência do aumento da taxa de crescimento da floresta, que vem se estabilizando, enquanto a

mortalidade das árvores vem aumentando, levando a uma perda de biomassa e um encurtamento do tempo de residência de carbono. Os autores atribuem como principal causa desses aumentos na mortalidade a ocorrência de eventos climáticos extremos, cada vez mais recorrentes nas últimas décadas, a exemplo do último El Niño, no ano de 2015, que ocasionou secas severas na região amazônica.

FIGURA 4 – TENDÊNCIAS NA MUDANÇA DE BIOMASSA LÍQUIDA ACIMA DO SOLO (A), DA PRODUTIVIDADE (B) E DA EM MORTALIDADE DE BIOMASSA (C) EM 321 PARCELAS ESTUDADAS.



FONTE: adaptado de Brien et al. (2015).

As tendências mostradas na Figura 4 revelam uma tendência de declínio no acúmulo de carbono da floresta amazônica, divergindo das ideias propostas por outros autores, que preveem, para as próximas décadas, um aumento na absorção terrestre de carbono em escala global (HUNTINGFORD et al., 2013). Entretanto, tais divergências entre os estudos demonstram o quanto se deve dar atenção ao balanço de carbono nas florestas tropicais para que então se chegue a uma estimativa precisa dos estoques de carbono e biomassa nestas florestas. Além disso, denota a dificuldade ainda existente em termos de se prever o papel dos *feedbacks* da

vegetação terrestre na modulação da mudança global do clima (BOOTH et al., 2012; FRIEND et al., 2014).

Um dos maiores reservatórios de carbono no planeta Terra é a floresta amazônica (FELDPAUSCH et al., 2012). E, tendo em vista sua relevância no sequestro de carbono atmosférico, planos de mitigação climática firmados nos últimos anos têm dado enfoque em medidas e ações no ecossistema amazônico brasileiro.

2.3 ESTOQUES DE BIOMASSA E CARBONO NO BRASIL E NA AMAZÔNIA

2.3.1 Brasil

A área oficial do Brasil é de 8,5 milhões de km² (IBGE, 2020a), dos quais cerca de 4,9 milhões de km² são cobertos por florestas naturais (FAO, 2020). Nesse contexto, os estoques de biomassa e carbono nas florestas brasileiras podem ser analisados para cada um dos seis biomas. Os biomas Amazônia, Caatinga, Cerrado, Mata Atlântica, Pampa e Pantanal abrangem as áreas de floresta, em hectares, de 319 milhões, 36 milhões, 75 milhões, 19 milhões, 2,6 milhões e 5,5 milhões, respectivamente (FAO, 2020). De acordo com o último relatório FRA (*Global Forest Resources Assessment*) da FAO (*Food and Agriculture Organization of the United Nations*), os estoques atuais (ano de referência: 2020) de biomassa e carbono, acima do solo, nos biomas brasileiros são os seguintes (TABELA 1):

TABELA 1 – ESTOQUES DE BIOMASSA E CARBONO ACIMA DO SOLO NOS BIOMAS BRASILEIROS.

Bioma	Biomassa (milhões de megagramas)	Carbono (milhões de megagramas)
Amazônia	77.245,59	38.144,31
Caatinga	711,31	348,54
Cerrado	3.323,26	1.620,11
Mata Atlântica	1.258,57	616,7
Pampa	156,43	76,65
Pantanal	391,75	184,34

FONTE: FAO (2020).

Há, ainda, inúmeros estudos que quantificaram os estoques de biomassa e carbono, em nível regional, a partir de equações de biomassa. Alguns exemplos podem ser citados para os biomas Caatinga (DA SILVA; MATOS; FERREIRA, 2008; DAVID et al., 2017), Cerrado (VENTUROLI; SANQUETTA, 2019) e Mata Atlântica (FIORENTIN et al., 2015). Além disso, técnicas de aprendizado de máquina também têm sido aplicadas nas estimativas de carbono na Mata Atlântica, em florestas de araucária (SANQUETTA et al., 2013).

Um ponto a ser destacado no último relatório FRA refere-se à redução nos valores de biomassa e carbono estocados nos biomas brasileiros. Entre os anos de 1990 e 2020, os estoques de biomassa passaram de 95,6 para 83,1 gigatoneladas, e os estoques de carbono, que eram 47,1, reduziram para 41 gigatoneladas. Ou seja, em 30 anos, houve perdas dos estoques de biomassa e carbono acima do solo na ordem de 15,08% e 14,88%, respectivamente.

Ainda de acordo com o relatório FRA (FAO, 2020), o bioma Amazônia concentra 77,2 Gt de biomassa, e 38,1 Gt de carbono. Contudo, entre os anos de 1990 de 2020, houve redução expressiva, de 13,02% e 12,80%, nos estoques de biomassa e carbono, respectivamente, nesse bioma.

2.3.2 Amazônia

Um dos maiores reservatórios de carbono no planeta Terra é a floresta amazônica, com um estoque total estimado de cerca de 150-200 Gt C, na forma de biomassa viva e nos solos (FELDPAUSCH et al., 2012). Estudos recentes, baseados em inventários florestais na Bacia Amazônica, mostram que a floresta amazônica atua como um importante sumidouro de carbono, com uma capacidade estimada de ter assimilado 0,42-0,65 Gt C ano⁻¹ entre os anos de 1990-2007. Isso corresponde a cerca de 25% do estoque total de carbono terrestre assimilado no mesmo período (PHILLIPS et al., 2009; PAN et al., 2011).

Para florestas tropicais, incluindo a floresta amazônica, a equação alométrica mais utilizada para estimativas de biomassa acima do solo, com validação a partir de estimativas obtidas de imagens de satélite, foi obtida por meio da derrubada e pesagem de, aproximadamente, 4.004 árvores (CHAVE et al., 2014). Outros estudos desenvolveram equações de biomassa em nível regional, para localidades nos estados do Amazonas (HIGUCHI et al., 2004) e Pará (MAZZEI et al., 2010).

Observa-se na TABELA 2, abaixo, os valores de biomassa acima do solo, por unidade de área, encontrados nos principais estudos já publicados (SAATCHI et al., 2011; BACCINI et al., 2012; MCTI, 2015; FAO, 2020). Nota-se que os relatórios do *Global Forest Resources Assessment*, publicado pela FAO (FAO, 2020), e do Terceiro Inventário Brasileiro de Emissões e Remoções Antrópicas de Gases de Efeito Estufa (MCTI, 2015) reportam valores de biomassa por tipologia florestal.

TABELA 2 – ESTIMATIVAS DE BIOMASSA ACIMA DO SOLO REPORTADAS NA LITERATURA, PARA A AMAZÔNIA BRASILEIRA E FLORESTAS TROPICAIS.

Autores	Tipologia florestal	Biomassa acima do solo (Mg ha⁻¹)
MCTI (2015)	Amazônia brasileira/Floresta densa	273,79
MCTI (2015)	Amazônia brasileira/Floresta aberta	231,71
FAO (2020)	Amazônia brasileira/Floresta densa	267,56
FAO (2020)	Amazônia brasileira/Floresta aberta	230,06
Saatchi et al. (2011)	Florestas tropicais	255,00
Baccini et al. (2012)	Florestas tropicais	285,50

FONTE: A AUTORA (2021).

No relatório publicado pelo governo brasileiro (MCTI, 2015), encontram-se os maiores valores de biomassa total acima do solo (273,69 Mg ha⁻¹ e 231,71 Mg ha⁻¹, para floresta densa e floresta aberta, respectivamente). Esses valores podem ser justificados pelo uso de fatores de expansão de biomassa para inclusão da biomassa de árvores com $10 \leq \text{DAP} < 30$ cm, além fatores de expansão para inclusão de palmeiras, cipós, sub-bosque, madeira morta, serapilheira e estrato herbáceo. No relatório do FRA, valores de 267,56 Mg ha⁻¹ (floresta densa) e 230,06 Mg ha⁻¹ (floresta aberta) remetem às estimativas de biomassa viva acima do solo, incluindo indivíduos arbóreos e não arbóreos. A partir de mapas pantropicais de biomassa, publicados por Saatchi et al. (2011) e Baccini et al. (2012), valores médios de biomassa viva acima do solo, sem distinção por tipologias florestais, assemelham-se aos resultados reportados pelo *Global Forest Resources Assessment* (FAO, 2020).

Nos últimos anos, a tecnologia LiDAR tem se destacado na quantificação de estoques de biomassa na Amazônia (LONGO et al., 2016; TEJADA et al., 2019; REX et al., 2020). Ademais, o uso dessa tecnologia, como supracitado, tem sido aplicada na elaboração dos mapas pantropicais de carbono e biomassa. Por fim, cita-se trabalhos recentes, os quais utilizaram algoritmos de aprendizado de máquina na predição de carbono e biomassa na Amazônia brasileira (DE ALMEIDA et al., 2019) e no estado do Pará (FENG et al., 2017).

2.4 MÉTODOS TRADICIONAIS DE QUANTIFICAÇÃO DE BIOMASSA

As estimativas de biomassa atualmente disponíveis na literatura, para diversas tipologias florestais, vêm de estudos que utilizam métodos diretos e indiretos (BROWN; GILLESPIE; LUGO, 1989), com informações obtidas por meio de levantamentos florestais. O método direto consiste na derrubada de todas as árvores que ocorrem em parcelas fixas e posterior pesagem de todos os seus compartimentos (tronco, galhos grossos, galhos finos, folhas e raízes) para a obtenção da biomassa total. No método indireto, as estimativas têm sido produzidas a partir de dados de inventários florestais (HIGUCHI et al., 2004). Esse método se baseia na utilização de equações de biomassa para a estimativa de biomassa e carbono, a partir de variáveis preditoras (por exemplo, diâmetro e altura das árvores). A estimativa do estoque de carbono da vegetação pode ser obtida pelo produto da biomassa florestal e concentração de carbono. A concentração de carbono na vegetação, obtida por Higuchi; Carvalho Jr. (1995), está em torno de 48%, valor este que está dentro dos limites de concentrações em florestas tropicais, entre 46 e 52%.

A variável independente mais utilizada para a estimativa de biomassa nos inventários florestais, a partir do método indireto, é o DAP (diâmetro à altura do peito, obtido a 1,30 m acima do solo), por ser considerada uma variável de fácil obtenção (menor tempo e custos). Além do DAP, outras variáveis independentes podem ser utilizadas, como a altura, o volume e a densidade da madeira. Para florestas tropicais, a equação alométrica mais utilizada para estimativas de biomassa acima do solo, com validação a partir de estimativas obtidas de imagens de satélite, foi obtida por meio da derrubada e pesagem de 4.004 árvores (CHAVE et al., 2014).

A biomassa florestal também pode ser estimada a partir de métodos de sensoriamento remoto, como radares e a tecnologia LiDAR (*Light Detection and*

Ranging). Watzlawick; Kirchner; Sanquetta (2009) enaltecem que o uso de imagens de satélite para estimar o volume de madeira e biomassa pode ser considerado uma técnica mais fácil e menos onerosa para obtenção de dados, além de permitir obtenção de informações sobre áreas remotas e inacessíveis. Nesse sentido, devido à ampla cobertura espacial dos ecossistemas florestais, além da necessidade de análises temporais, a combinação de métodos de inventário florestal com técnicas de sensoriamento remoto é imprescindível.

Outras metodologias têm sido abordadas nas estimativas de biomassa e carbono, tais como a aplicação de algoritmos de aprendizado de máquina, um subcampo da inteligência artificial. Estudos apontam que a aplicação de técnicas de aprendizado de máquina tem proporcionado melhores resultados que a regressão linear nas estimativas de biomassa, como também em estudos da forma do fuste das árvores, demonstrando a simplicidade, versatilidade e flexibilidade destes métodos quando aplicados sob uma ampla gama de condições (SANQUETTA et al., 2015; SCHIKOWSKI et al., 2018; SOUZA et al., 2019).

2.5 NOVAS TÉCNICAS PARA QUANTIFICAÇÃO DE BIOMASSA FLORESTAL

A análise e interpretação de dados consiste em uma importante etapa na tomada de decisões nas mais diversas áreas de conhecimento, e o mesmo acontece na área florestal. Em anos recentes, novas técnicas de análise de dados vêm sendo desenvolvidas, tendo como objetivo principal a automatização de processos e modelos analíticos (FACELI et al., 2011) e diminuição dos custos dos levantamentos florestais.

Geotecnologias, automação, robótica e sistemas de otimização já são tecnologias amplamente utilizadas em vários setores da economia e passíveis de serem incorporadas em outras áreas, como é o caso do manejo florestal. Ademais, destacam-se os algoritmos de aprendizado de máquina (*machine learning*), um subcampo da inteligência artificial que consiste no processo pelo qual os computadores desenvolvem a capacidade de reconhecimento de padrões, bem como a capacidade de treinamento a partir de dados para fins de prover estimativas, dada sua flexibilidade no treinamento e modelagem das relações entre variáveis (BINOTI et al., 2014). Tais técnicas vêm sendo cada vez mais utilizadas nas estimativas de

parâmetros florestais, devido à flexibilidade no treinamento e modelagem das relações entre variáveis (BINOTI et al., 2014).

2.5.1 Geotecnologias

Apesar de as atividades de inventário florestal fornecerem valiosas informações para a geração de estimativas de biomassa e carbono em ecossistemas florestais (ZHENG et al., 2007), configura-se como um método espacialmente limitado (WEST; WEST, 2009). Nesse sentido, devido à ampla cobertura espacial dos ecossistemas florestais, além da necessidade de análises temporais, a combinação com técnicas de sensoriamento remoto é imprescindível. O uso de sensores remotos melhorou os métodos de amostragem terrestre, permitindo uma melhor avaliação dos recursos florestais em várias escalas (BREIDENBACH; ASTRUP, 2012).

As geotecnologias apresentam diversas vantagens em relação a outras técnicas tradicionais de trabalho de campo, pois possibilitam a aquisição de informações em locais de difícil acesso, uso de diferentes escalas, informações homogêneas em escala temporal e informações de livre acesso (CASTILLO et al., 2015). Vine; Sathaye (1997) sugeriram que, para a obtenção de estimativas mais precisas de biomassa acima do solo em vastas extensões territoriais, é importante combinar técnicas de sensoriamento remoto com técnicas de inventário florestal.

As seguintes subseções descrevem as principais ferramentas geotecnológicas utilizadas nos dias atuais, com exemplos de aplicação nas estimativas de biomassa e carbono em ecossistemas florestais. Por fim, citam-se dois exemplos de projetos que têm aplicado ferramentas de geotecnologias nas estimativas de biomassa e carbono em ecossistemas florestais.

2.5.1.1 Imagens de satélite

A análise de imagens de satélites para caracterização das florestas tem sido uma ferramenta amplamente utilizada nas últimas décadas. A facilidade, cada vez maior, de acesso a imagens de diversos sensores, aliada aos avanços nas resoluções espaciais, temporais e espectrais, combinado a novas ferramentas para processamento digital das imagens, propiciam a realização de estudos que integram as técnicas de sensoriamento remoto com inventário florestal.

Imagens provenientes dos satélites Landsat 5 e 8 e CBERS-2 são destaque em estudos de monitoramento de recursos florestais, principalmente ao que se refere a monitoramentos e análises temporais. Além disso, atualmente, destacam-se as imagens Pléiades (com resolução espacial de 2 m), que podem ser obtidas gratuitamente, bem como imagens Sentinel-2, com resolução de 10 m.

Como exemplos a serem citados, para estimativas de biomassa e carbono, Watzlawick; Kirchner; Sanquetta (2009) utilizaram imagens do satélite IKONOS II em florestas de araucária no sul do Brasil. Na Amazônia brasileira, Lu et al. (2007) utilizaram imagens Landsat TM para estimar a biomassa florestal no estado do Pará.

2.5.1.2 LiDAR

Uma ferramenta alternativa e complementar às imagens de satélite que tem ganhado destaque nos últimos anos é a tecnologia LiDAR (do inglês, *Ligh Detection and Ranging*), que consiste na emissão de pulsos *laser* nos alvos a serem analisados, em um processo de escaneamento, para determinar a distância entre os objetos e, conseqüentemente, suas dimensões (ASNER et al., 2015).

Os sistemas LiDAR basicamente estão apoiados sob três tipos de plataformas: *laser scanner* aerotransportado, do acrônimo em inglês ALS (*Airbone Laser Scanner*), *laser scanner* terrestre, TLS (*Terrestrial Laser Scanner*), UAV-LiDAR (*Unmanned Aerial Vehicles-LiDAR*) e LiDAR orbital. Mais recentemente, pode-se citar o uso de veículos aéreos não tripulados (VANTs) com sensor LiDAR (HYYPÄ et al., 2015; WHITE et al., 2016), e até mesmo o uso de sistema LiDAR portátil terrestre acoplado em mochila (BERBERT, 2016).

A tecnologia LiDAR tem sido cada vez mais aplicada para quantificar a estrutura vertical das florestas e obtenção de métricas usualmente obtidas por meio de inventários florestais, tais como a altura das árvores e diâmetro de copa, utilizando *laser scanner* aéreo (ALS) (REX, 2019). Ainda, é possível a obtenção de estimativas de altura, diâmetro e volume de árvores a partir do *laser scanner* terrestre (TLS) (VASCONCELLOS, 2020, submetido à publicação). O uso dessa ferramenta também expande-se em estudos de estimativas de biomassa acima do solo (SIMONSON et al., 2016). Alguns autores destacam que a integração com a tecnologia LiDAR confere estimativas mais acuradas de biomassa (NIE et al., 2017; BAZEZEW; HUSSIN; KLOOSTERMAN, 2018).

Em termos de estimativas de biomassa florestal, o principal uso de dados LiDAR remete à elaboração de acurados mapas de biomassa e carbono pantropicais. Saatchi et al. (2011) elaboraram um mapa de biomassa, acima e abaixo do solo, na extensão dos domínios tropical e subtropical do globo terrestre, combinando dados de campo (inventários florestais) com dados LiDAR. Já em nível de florestas tropicais, Baccini et al. (2012) e Avitabile et al. (2016) elaboraram mapas pantropicais de biomassa com base em observações de dados LiDAR.

O uso da tecnologia LiDAR em ambientes temperados na América do Norte e na Ásia também é recorrente (ZHENG et al., 2007; HUDAK et al., 2012). Em nível regional, comenta-se o uso de dados LiDAR para gerar estimativas de biomassa acima do solo em florestas de araucária no sul do Brasil (REX et al., 2019).

Para a floresta amazônica brasileira, há inúmeros estudos recentes que integraram dados de campo com dados de sensoriamento remoto, obtidos, principalmente, com LiDAR aéreo (D'OLIVEIRA et al., 2012; MASCARO et al., 2014; LONGO et al., 2016; TEJADA et al., 2019; REX et al., 2020).

Também cabe citar que, em dezembro de 2018, foi lançado pela Estação Espacial Internacional o instrumento *Global Ecosystem Dynamics Investigation* (GEDI), o qual se configura como o primeiro *laser* de alta resolução para análise da estrutura 3D da Terra, com realização de medições precisas da altura do dossel da floresta, estrutura vertical do dossel e elevação da superfície (GEDI, 2019).

A missão GEDI (*Global Ecosystem Dynamics Investigation*), um projeto da NASA (Agência Espacial dos Estados Unidos), foi lançado em 2018 para uma missão de dois anos, com o objetivo de criar mapas em 3D das florestas, bem como da topografia da Terra. Uma das principais motivações científicas do GEDI é fornecer uma avaliação quantitativa, consistente e globalmente transparente da distribuição espacial dos estoques de carbono nas florestas do mundo, em resoluções espaciais relevantes para o monitoramento e verificação dos estoques de carbono (GEDI, 2019). A partir de dados GEDI (sensor LiDAR), estimativas de biomassa em grades de 1 km serão geradas, juntamente com suas incertezas associadas.

No Brasil, o Projeto Paisagens Sustentáveis Brasil, lançado no ano de 2016 no âmbito da EMBRAPA (Empresa Brasileira de Pesquisa Agropecuária) em parceria com o Serviço Florestal dos Estados Unidos, teve por principal objetivo o desenvolvimento de novas metodologias e conhecimento, para estimativas de carbono no âmbito do REDD+, entre eles o uso de dados LiDAR (EMBRAPA, 2014).

A plataforma WebGIS Paisagens Sustentáveis Brasil é uma ferramenta que concentra o maior acervo de dados provenientes de levantamentos realizados com a tecnologia LiDAR do Brasil, bem como dados de inventários florestais em localidades nos biomas Amazônia, Cerrado e Mata Atlântica. O download dos dados do projeto pode ser realizado em: <https://www.paisagenslidar.cnptia.embrapa.br/webgis/>.

2.5.1.3 Satélites Sentinel

Recentemente, imagens dos satélites Sentinel-1 (SAR – imagens de Radar de Abertura Sintética) e Sentinel-2 (multiespectral) têm sido cada vez mais utilizadas para estimar métricas florestais. A família Sentinel é formada por um conjunto de satélites que foram concebidos e desenvolvidos pela Agência Espacial Europeia, no âmbito do Projeto Copernicus. Os dados adquiridos por estas missões são disponibilizados gratuitamente (<https://sentinel.esa.int/web/sentinel/sentinel-data-access>).

A análise de imagens dos satélites Sentinel-1 e Sentinel-2 também se configuram como uma nova alternativa para mapeamento e monitoramento de biomassa terrestre, especialmente nos trópicos (CASTILLO et al., 2015). Podem ser mencionados trabalhos que utilizaram imagens Sentinel para geração de estimativas de biomassa em diversos ambientes, tais como florestas temperadas na Índia (NINGTHOUJAM; JOSHI; ROY, 2018) e na China (CHEN et al., 2018), floresta boreal na Europa (WITTKE et al., 2019) e manguezais nas Filipinas (CASTILLO et al., 2015).

No Brasil, o uso de imagens Sentinel também tem ganhado destaque em estudos florestais. Por exemplo, Sothe et al. (2017) combinaram imagens de Sentinel-2 e Landsat-8 para mapear estágios sucessionais na Mata Atlântica. Para estimativas de biomassa e carbono em ambientes tropicais, mais especificamente, Debastiani et al. (2019) estimaram a biomassa acima do solo para dados de parcelas florestais na Amazônia brasileira, utilizando a banda SAR dos satélites Sentinel 1 e 2. Berninger et al. (2018), também a partir da banda SAR, estimaram a biomassa acima do solo em floresta tropical na Ásia.

2.5.2 Algoritmos de aprendizado de máquina

Os algoritmos de aprendizado de máquina têm sido amplamente aplicados à área florestal. Esses algoritmos são divididos em duas categorias, de acordo como

tipo de aprendizado: 1. Aprendizado supervisionado, tais como KNN (*k-Nearest Neighbors*), SVM (*Support Vector Machine*), RNA (Redes Neurais Artificiais) e Random Forest; 2. Aprendizado não supervisionado, como regras de associação (*Association Rule Learning*) e agrupamento (Cluster). Exemplos de aplicações podem ser citados nos campos de predição de incêndios florestais (VASILAKOS et al., 2009; SAKR et al., 2010), modelagem da diversidade da paisagem (GIL-TENA et al., 2011) e suscetibilidade da paisagem (PHAM et al., 2018), caracterização da cobertura florestal (BLACKARD; DEAN, 1999), aplicação em modelos de crescimento (CASTRO et al., 2013) e predição de mortalidade de árvores (HASENAUER; MERKL; WEINGARTNER, 2001). Uma boa revisão de literatura sobre esse tema foi realizada por Imada (2014), em artigo no qual se detalham as técnicas de aprendizado de máquina utilizadas nos trabalhos citados anteriormente.

Mais recentemente, estudos investigaram o uso das técnicas de aprendizado de máquina na tomada de decisão no corte seletivo de árvores em florestas tropicais (HETHCOAT et al., 2019), bem como na estimativa de forma do fuste e volume em espécies florestais de interesse comercial no Brasil, como a acácia-negra (SCHIKOWSKI et al., 2018). Além disso, estudos recentes apontam que as técnicas de aprendizado de máquina têm proporcionado melhores resultados que a regressão linear nas estimativas de biomassa, como também em estudos da forma do fuste das árvores, demonstrando a simplicidade, versatilidade e flexibilidade desses métodos quando aplicados sob uma ampla gama de condições (SANQUETTA et al., 2015; SCHIKOWSKI et al., 2018; SOUZA et al., 2019).

Outras aplicações do aprendizado de máquina remetem às estimativas de biomassa e carbono em florestas tropicais. Nas estimativas de biomassa na floresta amazônica brasileira, há pesquisas com aplicações de diferentes técnicas de aprendizado de máquina (MONTAÑO et al., 2017). Nesse trabalho, os autores testaram modelos de RNA, SVM e RF aplicados ao mesmo conjunto de dados pantropicais (4.004 árvores) utilizado por Chave et al. (2014). Conclui-se que a técnica de SVM apresentou melhor acurácia na estimativa de biomassa de árvores em florestas tropicais, para a base de dados considerada.

Em estudo recente, Souza (2020) desenvolveu o aplicativo web MLMBio em linguagem R, utilizando o pacote “shiny” (CHANG et al., 2020), para estimar valores de biomassa aérea em ambientes tropicais a partir de modelos de aprendizado de máquina. A partir desse aplicativo, é possível inserir dados de campo de inventário

florestal para estimar a biomassa de árvores a partir de três modelos, o pantropical de Chave et al. (2014), além de um modelo de ANN (*Artificial Neural Network*) e um terceiro de Random Forest, o SGB (*Stochastic Gradient Boosting*), os quais foram considerados os modelos mais acurados para estimativa de biomassa aérea de árvores em florestas tropicais, de acordo com os resultados encontrados por Souza (2020).

Ademais, para outras florestas nativas brasileiras, há estudos que compararam estimativas de biomassa obtidas por meio de data mining – técnica KNN – com técnicas convencionais (regressão linear) na Mata Atlântica brasileira (SANQUETTA et al., 2015) e em povoamentos de *Araucaria angustifolia* (SANQUETTA et al., 2013).

2.6 INTELIGÊNCIA ARTIFICIAL (IA)

Inteligência Artificial pode ser definida como “A subárea da ciência da computação que compreende o projeto de sistemas computacionais que exibam características que se associam à inteligência no comportamento humano - compreensão da linguagem, aprendizado, raciocínio, solução de problemas e assim por diante” (BARR; FEIGENBAUM, 1981).

A primeira menção oficial à expressão “Inteligência Artificial” ocorreu nos anos 50, mais especificamente no ano de 1956, em uma conferência em *Dartmouth College* (EUA), quando John McCarthy (Dartmouth), Marvin Minsky (Harvard), Nathaniel Rochester (IBM) e Claude Shannon (Bell Laboratories) comentaram que iriam realizar um estudo durante dois meses, por dez homens, sobre o tópico Inteligência Artificial (MCCORDUCK, 1979). O artigo do matemático Alan Turing, intitulado “*Computing Machinery and Intelligence*” e publicado em 1950 (TURING, 1950), também é considerado um marco no desenvolvimento de pesquisas que viriam, então, a fundamentar os pilares de criação da Inteligência Artificial.

Os sistemas de IA podem seguir quatro linhas de pensamento (GEETHA; BHANU, 2018; RUSSELL; NORVIG, 1995):

1. Sistemas que agem como os seres humanos

O exemplo clássico de aplicação desse sistema é o “teste de Turing” - também conhecido como “jogo da imitação” -, desenvolvido pelo matemático inglês Alan Turing (TURING, 1950). Neste, Alan Turing propôs que um humano interagisse com dois

jogadores, A e B, trocando mensagens escritas em um bate-papo. Caso o interrogador humano não pudesse determinar, entre os jogadores A e B, qual era um computador e qual era um ser humano, o computador, então, era bem-sucedido, ou seja, passava no teste de inteligência. O argumento é que, se um computador é indistinguível de um humano em uma conversa geral de linguagem natural, ele deve ter alcançado a inteligência em nível humano.

2. Sistemas que pensam como seres humanos

O campo da ciência cognitiva reúne modelos de computador da IA e técnicas experimentais da psicologia para tentar construir teorias precisas e testáveis sobre o funcionamento da mente humana, tentando modelar como os humanos pensam. A diferença entre sistemas que agem como seres humanos e sistemas que pensam como seres humanos é que o primeiro dá enfoque apenas nas ações, no resultado ou produto dos processos de pensamento humanos, enquanto o último dá enfoque na modelagem dos processos de pensamento humanos.

3. Sistemas que pensam de forma racional

Nesse sistema, modela-se o pensamento como um processo lógico, cujas conclusões são tiradas com base em algum tipo de lógica simbólica. Em 1965, existiam programas que podiam, com tempo e memória suficientes, obter uma descrição de um problema em notação lógica e encontrar a solução, se houvesse. Entretanto, o programa não era interrompido até encontrar uma solução. A tradição dita lógica dentro da inteligência artificial se baseia em tais programas para criar sistemas inteligentes.

4. Sistemas que agem de forma racional

Remete ao estudo dos agentes racionais ou agentes inteligentes: agentes que maximizam o valor esperado de sua medida de desempenho, dado o que sabem atualmente. Um agente é apenas algo que percebe e age. Agir racionalmente significa agir de forma a atingir seus objetivos. Por exemplo, um agente que está jogando agirá racionalmente se tentar ganhar o jogo.

2.6.1 Aprendizado de máquina (AM)

Aprendizado de máquina (ou *machine learning*, em inglês) é uma subárea da Inteligência Artificial que pesquisa métodos computacionais relacionados à aquisição de novos conhecimentos, novas habilidades e novas formas de organizar o conhecimento já existente (FAYYAD; PIATETSKY-SHAPIO; SMYTH, 1996).

De acordo com Faceli et al. (2011, p. 3),

Em AM, computadores são programados para aprender com a experiência passada. Para tal, empregam um princípio de inferência denominado indução, no qual se obtêm conclusões genéricas a partir de um conjunto particular de exemplos. Assim, algoritmos de AM aprendem a induzir uma função ou hipótese capaz de resolver um problema a partir de dados que representam instâncias do problema a ser resolvido. Esses dados formam um conjunto, simplesmente denominado conjunto de dados.

Portanto, as técnicas de aprendizado de máquina (AM) têm grande aplicabilidade, nos dias atuais, na solução de problemas, a exemplo de: reconhecimento de palavras faladas; detecção de uso fraudulento de cartões de crédito; condução de automóveis, de forma autônoma, em rodovias; predição de taxas de curas de doenças; entre outras (FACELI et al., 2011).

As tarefas de aprendizado de máquina podem ser organizadas de acordo com o paradigma de aprendizado utilizado para resolver determinada tarefa. De acordo com esse critério, as tarefas de AM podem ser divididas em: 1. Preditivas; 2. Descritivas. Os algoritmos preditivos seguem o paradigma de aprendizado supervisionado. Já os algoritmos descritivos seguem o paradigma de aprendizado não supervisionado. Esses dois termos serão mais bem explicados nos tópicos a seguir.

2.6.1.1 Aprendizado supervisionado

O aprendizado supervisionado é caracterizado quando o processo de um algoritmo aprendendo com o conjunto de dados de treinamento pode ser pensado como um professor supervisionando o processo de aprendizado (FACELI et al., 2011). De acordo com Barr; Feigenbaum (1981) e Russell; Norvig (1995), no aprendizado supervisionado, o objetivo final é conhecido e tenta-se prever um valor mais próximo desse objetivo. Nesse paradigma de aprendizado, o modelo é treinado a partir de uma


série de dados que possua variáveis de entrada (independentes) e variáveis de saída (dependentes). O objetivo é treinar tão bem o algoritmo de tal forma que, quando há novos dados de entrada (x), pode-se prever as variáveis de saída (y):

$$y = f(x) \quad (1)$$

Essa função costuma ser chamada de “função alvo”, visto que representa uma função que um determinado algoritmo de aprendizado de máquina supervisionado visa aproximar. Os algoritmos de aprendizado supervisionado podem ser classificados em dois tipos:

- a. Algoritmos de classificação: quando a variável de saída é categórica, como “azul” ou “vermelho”, “masculino” ou “feminino”, “ausência” ou “presença” (FIGURA 5).

FIGURA 5 – EXEMPLO DE APLICAÇÃO DE ALGORITMO SUPERVISIONADO DE CLASSIFICAÇÃO NA DISTINÇÃO DO PESO (EIXO X) E ALTURA (EIXO Y) DE HOMENS E MULHERES.



FONTE: A AUTORA (2021).

Durante o treinamento, um algoritmo de classificação recebe pontos de dados com uma categoria atribuída. O trabalho de um algoritmo de classificação é, então, pegar um valor de entrada e atribuir a ele uma classe ou categoria na qual ele se encaixa com base nos dados de treinamento fornecidos.

Os principais algoritmos aplicados nas tarefas de classificação são:


- Redes Neurais Artificiais (RNA);
- *k-Nearest Neighbors* (KNN);
- Máquina de Vetores de Suporte (SVM, na sigla em inglês);
- Árvores de Decisão;
- Random Forest.

b. Algoritmos de regressão: a regressão é um processo estatístico preditivo em que o modelo tem por objetivo encontrar a relação entre variáveis dependentes e independentes. Para modelos de regressão linear simples, a fórmula é dada por:

$$y = ax + b \quad (2)$$

Qualquer relação entre duas variáveis numéricas, sendo uma independente e outra dependente, pode ser obtida a partir de modelos de regressão linear, a exemplo da relação entre as horas de estudo e as notas obtidas por estudantes em uma prova (FIGURA 6):

FIGURA 6 – EXEMPLO DE RELAÇÃO LINEAR: HORAS DE ESTUDO (EIXO X) E NOTAS DE ESTUDANTES EM UMA PROVA (EIXO Y).



FONTE: A AUTORA (2021).

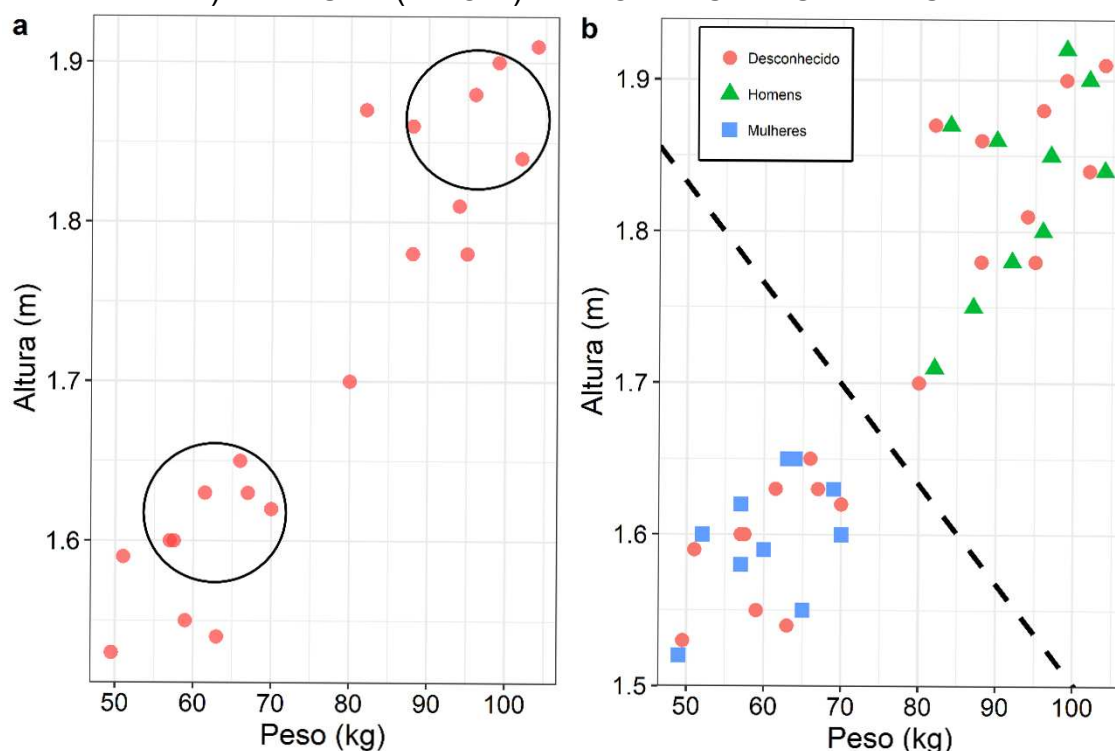
Os principais algoritmos aplicados nas tarefas de regressão são:

- Redes Neurais Artificiais;
- *k-Nearest Neighbors* (KNN);
- Random Forest (Florestas Aleatórias);
- Máquina de Vetores de Regressão (SVR, na sigla em inglês);
- Árvores de Regressão.

2.6.1.2 Aprendizado não supervisionado

No aprendizado não supervisionado, o objetivo é encontrar padrões nos dados. É chamado de aprendizado não supervisionado porque, diferentemente do aprendizado supervisionado, não há a ideia de um “supervisor externo” inspecionando o processo (BARR; FEIGENBAUM, 1981; RUSSELL; NORVIG, 1995). Os algoritmos são deixados por conta própria para discriminar ou agrupar dados. Em resumo, o aprendizado de máquina não supervisionado não pode ser aplicado diretamente a uma regressão, pois não se sabe quais seriam os valores de entrada, sendo estes considerados valores desconhecidos (FIGURAS 7.A e 7.B).

FIGURA 7 – DIFERENÇA ENTRE ALGORITMOS DE APRENDIZADO NÃO SUPERVISIONADO (A) E SUPERVISIONADO (B) PARA DADOS DE PESO (EIXO X) E ALTURA (EIXO Y) DE HOMENS E MULHERES.



FONTE: A AUTORA (2021).

Algoritmos de aprendizado não supervisionado podem ser classificados em dois tipos:

- a. Agrupamento: também denominado de “cluster” ou “clusterização”, esses algoritmos visam dividir o conjunto de dados em subgrupos semelhantes. Ou seja, deseja-se descobrir os agrupamentos inerentes aos dados, como, por exemplo, agrupar clientes por comportamento de compra. A principal técnica aplicada para executar tarefas de agrupamento é chamada de *k-means*.
- b. Regras de Associação: aplica-se algoritmos de regras de associação quando se deseja descobrir regras que descrevem as relações entre os dados, como pessoas que compram determinado produto X também tendem a comprar o produto Y. Também determina quais fatos ou objetos tendem a ocorrerem juntos num mesmo evento. Um dos algoritmos mais comuns para resolver tarefas de regras de associação é o Apriori.

2.6.1.3 Processo de KDD (Knowledge Discovery in Databases)

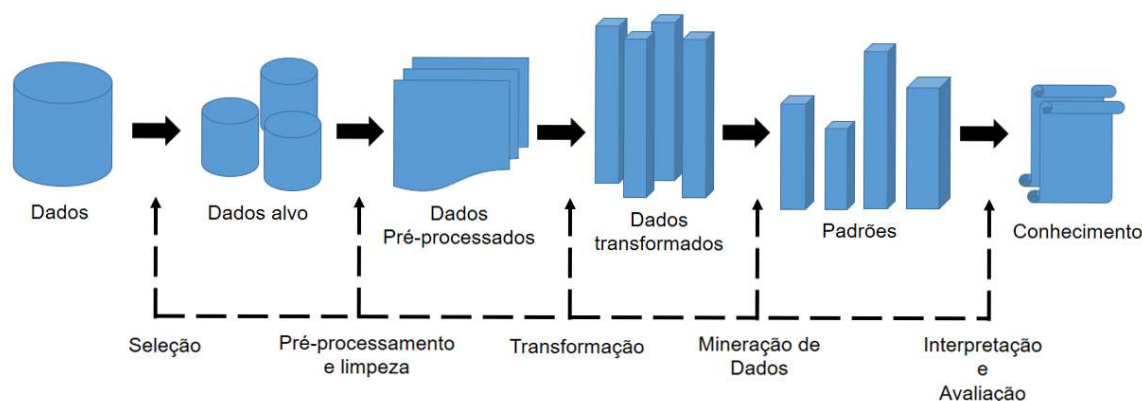
O processo de KDD (do inglês, Knowledge Discovery in Databases) trata-se de um processo de extração de informações úteis em uma base de dados, de forma automática ou semiautomática, usualmente aplicada a largas bases de dados, com o intuito de tornar os dados viáveis à aplicação de análises qualitativas e quantitativas (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996). O processo de KDD tem como meta principal a transformação de dados em conhecimento, ou seja, transformar os dados brutos em dados úteis para as pesquisas.

O uso das técnicas de KDD e Mineração de Dados (MD), em conjunto, são de fundamental importância para análise de dados automatizados, uma vez que facilitam a interpretação de conjuntos de dados, principalmente aqueles que consistem em grandes volumes de informação. Posto isso, é relevante citar que uma das razões para se recorrer às técnicas de MD e processo de KDD é porque, no mundo de hoje, tão tecnológico, o volume de informações está aumentando a cada dia, a exemplo de dados de transações comerciais, dados científicos ou, até mesmo, dados inseridos nas redes sociais. Para tanto, é necessário um sistema capaz - com técnicas eficazes - de extrair a essência das informações.

Sabe-se que as máquinas ainda estão longe de abordar habilidades humanas no que compete à síntese de conhecimento e formulação de hipóteses. No entanto, a automatização de procedimentos de redução e transformação de dados consiste em poder ser facilmente ensinadas às máquinas, facilitando assim a geração de conhecimento a partir dos dados (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996).

As principais etapas do processo de KDD consistem na seleção de dados, pré-processamento e limpeza, transformação, Mineração de Dados (etapa principal onde a extração de informações úteis é realizada por meio de diversas técnicas, principalmente as técnicas de Inteligência Artificial), interpretação e avaliação e, por fim, obtenção do conhecimento (FIGURA 8).

FIGURA 8 – ETAPAS DO PROCESSO DE KDD.



FONTE: adaptado de Fayyad; Piatetsky-Shapiro; Smyth (1996).

2.6.1.4 Mineração de Dados

Mineração de Dados, ou *Data Mining*, é um processo para descobrir automaticamente informações úteis em grandes repositórios de dados (TAN; STEINBACH; KUMAR, 2009). Outra definição explica que *Data Mining* é um conjunto de técnicas cujo propósito é vasculhar grandes bases de dados a fim de encontrar padrões novos e úteis que poderiam ficar desconhecidos ou escondidos na base (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996). As tarefas da Mineração de Dados podem ser de dois tipos:

- a) **Preditivas:** Através de dados de treinamento, tentam prever um resultado para outros dados apresentados. Exemplo:
 - Treinamento: Dado diâmetro de uma árvore, tem-se a altura conhecida;
 - Uso: dado diâmetro de uma árvore, estima-se a altura.
- b) **Descritivas:** Com um conjunto de dados, exploram ou descrevem estas informações. Exemplo:
 - Agrupamento de um conjunto de informações com as mesmas características.

Em outras palavras, Mineração de Dados é a extração não-trivial de informações úteis, é a exploração e análise, por meio automático ou semiautomático em grandes bases de dados a fim de descobrir padrões (TABELA 3):

TABELA 3 – EXEMPLOS DE TAREFAS QUE PODEM SER CLASSIFICADAS COMO MINERAÇÃO DE DADOS VERSUS TAREFAS QUE NÃO PODEM SER CLASSIFICADAS COMO MINERAÇÃO DE DADOS.

Tarefas de mineração de dados	Tarefas não classificadas como mineração de dados
Agrupar documentos similares	Buscar um nome em uma base de dados
Inferir valores a uma variável dependendo do valor de outras	Filtrar os produtos mais vendidos
Descobrir a qual classe determinado elemento pertence	Filtrar o nome de clientes

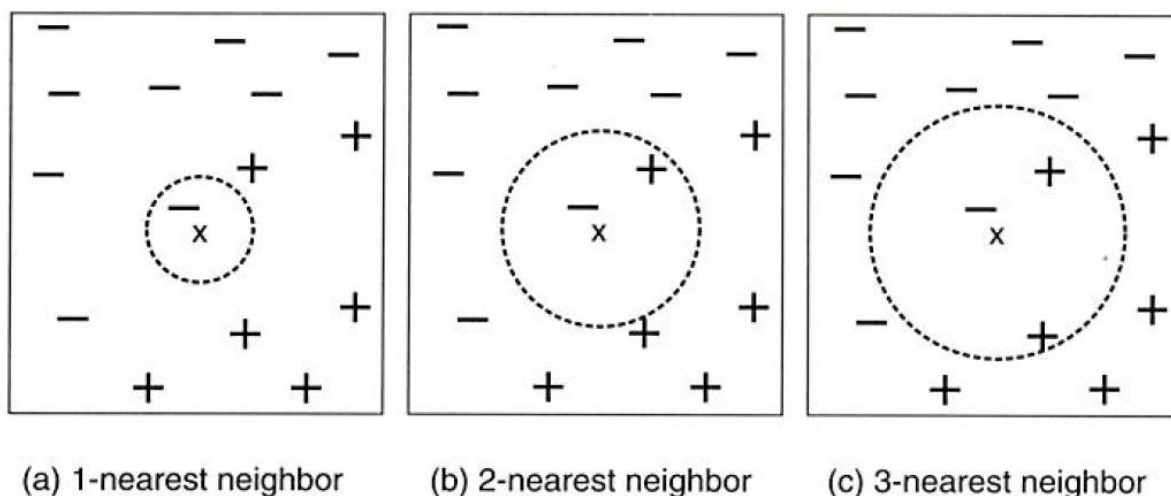
FONTE: A AUTORA (2021).

2.6.1.5 Principais algoritmos de aprendizado de máquina aplicados nas ciências florestais

a) KNN (*k-Nearest Neighbors*)

A Mineração de Dados utiliza diversas técnicas para explorar dados, entre as quais estão classificação e agrupamento (TAN; STEINBACH; KUMAR, 2009), como é o caso da Classificação Baseada em Instâncias. A Classificação Baseada em Instâncias (*Nearest-Neighbor Classifier*, em inglês) utiliza cada exemplo da base como um dado em um espaço de “n” dimensões, onde “n” é o número de atributos da instância (FIGURA 9). Dado um exemplo de teste, é calculada a distância para o restante dos exemplos da base, utilizando uma medida de proximidade (distância entre vetores). Essa técnica é também conhecida como KNN (*k-Nearest Neighbors*).

FIGURA 9 – VIZINHO MAIS PRÓXIMO DO CLASSIFICADOR BASEADO EM INSTÂNCIAS.



FONTE: TAN; STEINBACH; KUMAR (2009).

Nesse tipo de abordagem, é comum a ocorrência de “ruídos”, que são instâncias não bem posicionadas na base (AHA; KIBLER; ALBERT, 1991). Isso significa que, mesmo uma determinada instância tendo suas dimensões dentro do padrão das demais, possui o valor da variável dependente muito diferente dos valores das outras instâncias. Essa instância, então, é chamada de “ruído” (diferente de um “outlier” que é um valor atípico e não aceitável para o conjunto de dados).

No caso das instâncias deste trabalho, um “ruído” seria uma árvore com valores de DAPs com outras instâncias da base, porém, com um valor de biomassa muito diferente dessas instâncias. O problema possível de ocorrer seria tomar como base o valor de biomassa da instância considerada como um “ruído”, o que poderia causar erros na estimativa. Visando minimizar a vulnerabilidade de se basear em informações de instâncias com essas características, a técnica de Classificação Baseada em Instância utiliza algumas variações da quantidade de vizinhos mais próximos.

Na aplicação de Mineração de Dados com Classificador Baseado em Instâncias, alguns parâmetros utilizados devem ser informados:

1. Tipos de Distância: as principais fórmulas utilizadas nos cálculos das distâncias são (TABELA 4):

TABELA 4 – FÓRMULAS DOS QUATRO TIPOS DE DISTÂNCIAS APLICADAS NO CÁLCULO DAS DISTÂNCIAS ENTRE VETORES.

Distância	Fórmula
Euclidiana	$d(p, q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (3)$
Quadrática	$d(p, q) = \sum_{i=1}^n (p_i - q_i)^2 \quad (4)$
Manhattan	$d(p, q) = \sum_{i=1}^n p_i - q_i \quad (5)$
Chebychev	$d(p, q) = \text{MAX} p_i - q_i \quad (6)$

Onde: d = distância; n = quantidade de árvores na amostra; p_i = vetor com as dimensões das árvores base da execução; q_i = vetor com as dimensões das árvores calculadas.

2. Quantidade de Vizinhos: o algoritmo dos vizinhos mais próximos tem variações definidas pelo número de vizinhos considerados. Nesse caso, cada objeto representa um ponto em um espaço definido pelos atributos, denominado de espaço de entrada (FACELI et al., 2011). Definida uma métrica nesse espaço, é possível calcular a distância entre dois pontos, a partir das fórmulas apresentadas acima (TABELA 4). O número de vizinhos usualmente aplicados nos modelos são 1, 3 ou 5, podendo-se até adotar um número maior de vizinhos.

3. Fatores de ponderação: os pesos mais usuais são o inverso da distância ($1/d$) e o inverso da distância ao quadrado ($1/d^2$).

A seguir, serão introduzidos alguns conceitos de Redes Neurais Artificiais, Máquinas de Vetores de Suporte (SVM), Máquina de Vetores de Regressão (SVR), Árvores de Regressão e Random Forest. No entanto, maiores detalhes sobre as

especificações desses modelos de aprendizado de máquina aplicados às Ciências Florestais podem ser encontrados em Montaño (2016, p. 11-24), Rex (2019, p. 32-38) e Souza (2020, p. 40-62).


b) Redes Neurais Artificiais

De acordo com Berry; Linoff (2004, p. 281),

As Redes Neurais Artificiais são técnicas que procuram reproduzir de maneira simplificada as conexões do sistema biológico neural. Estruturalmente, consistem em um número de elementos interconectados, chamados neurônios, organizados em camadas que aprendem pela modificação de suas conexões. Tipicamente, tem-se uma camada de entrada ligada a uma ou mais camadas intermediárias que são ligadas a uma camada de saída.

Portanto, Redes Neurais Artificiais consistem de populares técnicas de aprendizado de máquina que simulam o mecanismo de aprendizado de organismos biológicos, baseando-se no mecanismo de funcionamento dos neurônios humanos (AGGARWAL, 2018) (FIGURA 10).

FIGURA 10 – ESTRUTURA DAS CAMADAS EM REDES NEURAIIS ARTIFICIAIS, COM CAMADA DE ENTRADA (INPUT LAYER), CAMADA OCULTA (HIDDEN LAYER) E CAMADA DE SAÍDA (OUTPUT LAYER).

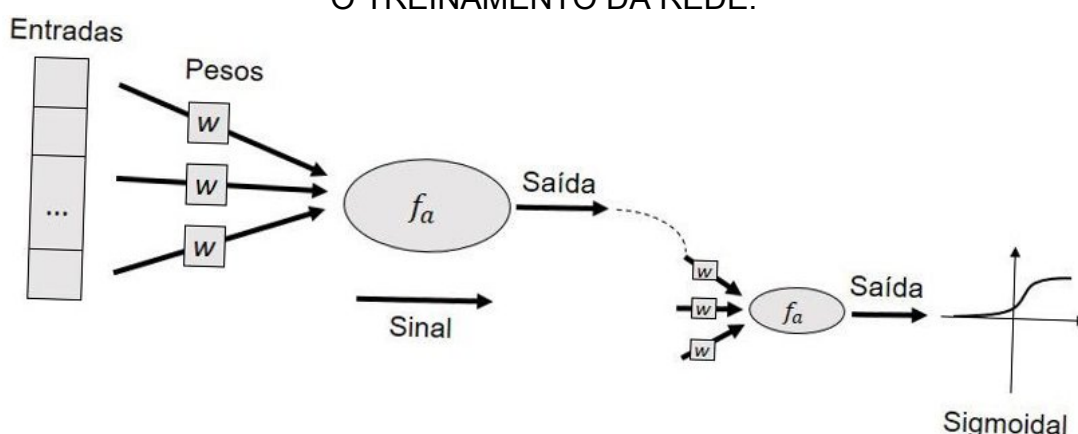


FONTE: A AUTORA (2021). ADAPTADO DE SWINGLER (1996).

O conceito de Rede Neural Artificial foi introduzido, pela primeira vez, no ano de 1943, por Warren McCulloch e Walter Pitts, no artigo intitulado "Logical Calculus of Ideas Immanent in Nervous Activity" (CHAKRAVERTY; SAHOO; MAHATO, 2019). Portanto, a rede de McCulloch-Pitt é considerada a primeira rede neural.

Em termos de algoritmo de aprendizado de máquina, redes neurais artificiais consistem de modelos estatísticos de sistemas reais que são construídos ajustando uma série de parâmetros (SKAPURA, 1996). Esses parâmetros, conhecidos como “pesos” ou “*weights*”, descrevem um modelo que forma um mapeamento de um dado conjunto de valores, conhecidos como “entradas” ou “*inputs*”, para um conjunto associado de valores: as “saídas” ou “*outputs*” (SWINGLER, 1996) (FIGURA 11).

FIGURA 11 – ESTRUTURA DE UM NEURÔNIO ARTIFICIAL, COM VALORES DE ENTRADA, PESOS, FUNÇÃO MATEMÁTICA DE ATIVAÇÃO (f_a) E SAÍDAS APÓS O TREINAMENTO DA REDE.



FONTE: A AUTORA (2021). ADAPTADO DE FACELI ET AL. (2011).

O processo de ajuste dos pesos para os valores corretos – chamado de “treinamento” – é realizado passando um conjunto de exemplos de pares de entrada-saída pelo modelo e ajustando os pesos a fim de minimizar o erro entre a resposta que a rede dá e a saída desejada (SWINGLER, 1996). Portanto, o aprendizado ocorre alterando os pesos que conectam os neurônios (AGGARWAL, 2018). Na estrutura de uma RNA, a função de ativação tem por objetivo limitar ou restringir a amplitude do valor de saída de um neurônio (HAYKIN, 2007).

O exemplo a seguir foi retirado de Aggarwal et al. (2018) para ilustrar o funcionamento de uma rede neural. Os dados de treinamento podem conter representações de pixel de imagens (entrada) e rótulo (label) anotado (por exemplo, imagem de uma cenoura, ou banana) como a saída. Esse par de dados de

treinamento é alimentado na rede neural usando as representações de entrada para fazer previsões sobre os rótulos de saída. Os dados de treinamento fornecem um feedback para a exatidão dos pesos na rede neural, dependendo de quão bem a saída prevista (por exemplo, probabilidade de ser a imagem de uma cenoura) para uma determinada entrada coincida com o rótulo de saída anotado nos dados de treinamento.

Portanto, na etapa de treinamento da rede neural, é calculado um erro entre o valor estimado e o valor real de saída (observado). Esse erro é propagado para as camadas da rede e, então, os dados são novamente passados pela rede para uma nova estimativa, processo este que pode ser repetido inúmeras vezes.

A separação dos dados da base de treinamento pode ser realizada por meio de duas principais técnicas:

1. Hold-out: técnica de separação dos conjuntos de treinamento e validação, em que se separa 2/3 (dois terços) dos dados para treinamento e 1/3 (um terço) dos dados para validação. Usada quando se tem grande número de dados disponíveis;
2. Cross-validation: o algoritmo usa 90% dos dados para treinamento e 10% para validação, porém, alternando esses 10% até que todas as décimas partes participem da validação. Usado quando se tem um número pequeno de dados disponíveis.

Em redes neurais de camadas simples (*single-layer networks*, no termo em inglês), um conjunto de entradas é mapeado diretamente para uma saída, usando uma variação generalizada de uma função linear. Essa simples instanciação de uma rede neural também é chamada de *perceptron* (AGGARWAL, 2018). Já nas redes neurais do tipo *Perceptron* de múltiplas camadas (*Multi-Layer Perceptron*, no termo em inglês), os neurônios são organizados em camadas, nas quais as camadas de entrada e saída são separadas por um grupo de camadas ocultas (*hidden layers*, no termo em inglês) ou intermediárias (FATH; MADANIFAR; ABBASI, 2018).

O *back-propagation* (retropropagação de erro) é o algoritmo mais popular para treinamento de uma rede MLP (*Multi-Layer Perceptron*). O objetivo do algoritmo *back-propagation* é otimizar os pesos para que a rede neural possa aprender a mapear corretamente as entradas para as saídas (HAYKIN, 2007). Portanto, é um

procedimento de aprendizado supervisionado que busca minimizar o erro entre a saída desejada e a prevista (GEVREY; DIMOPOULOS; LEK, 2003).

c) Support Vector Machine (SVM) e Support Vector Regression (SVR)

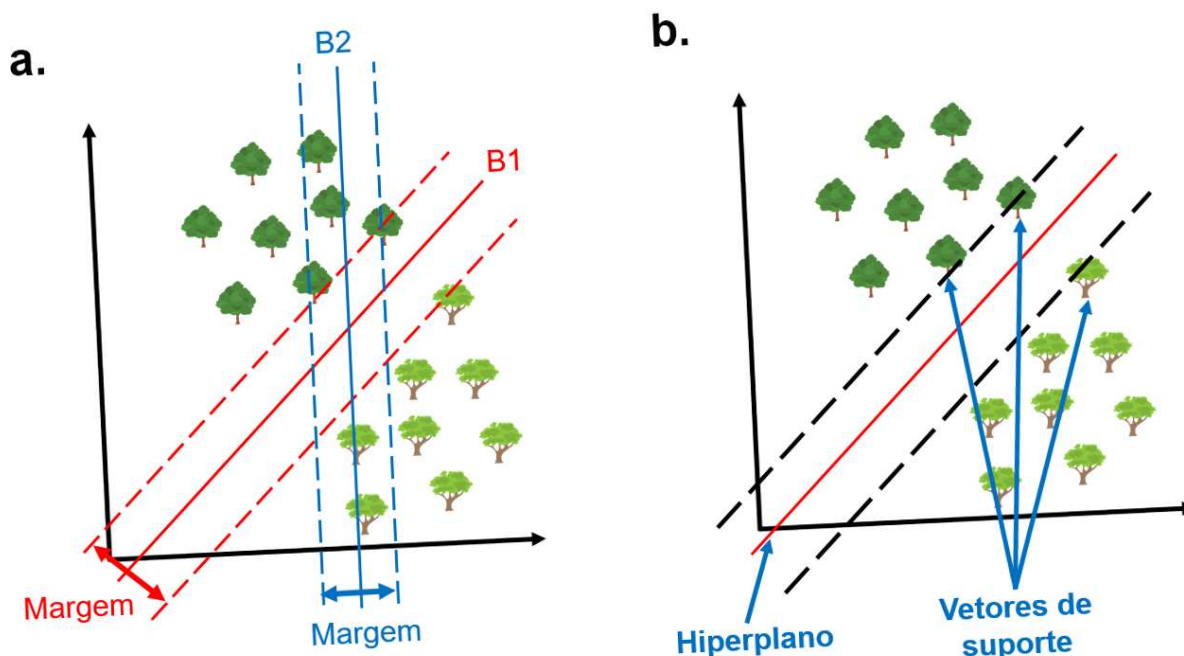
O conceito de Support Vector Machine (SVM), ou Máquina de Vetores de Suporte, surgiu a partir de estudos de Vapnik; Chervonenkis (1971) e Vapnik (1982). Em essência, SVM consiste em um algoritmo computacional para maximizar uma função matemática particular em relação a um determinado conjunto de dados, encontrando um modelo matemático a partir de dados de treinamento (NOBLE, 2006). O algoritmo SVM é fundamentado na teoria de aprendizado estatístico e foi desenvolvido, originalmente, para classificação de padrões (VAPNIK; CHERVONENKIS, 1971).

Portanto, quando criado, o algoritmo SVM tinha por finalidade resolver somente problemas de classificação (KUHN; JOHNSON, 2013). Entretanto, em anos recentes, o algoritmo SVM foi aperfeiçoado por Vapnik (1995), no sentido de também resolver problemas de regressão, criando um novo método chamado Support Vector Regression (SVR) ou Máquinas de Vetores de Regressão (BURGES, 1998; SMOLA; SCHÖLKOPF, 2004). Em resumo, os algoritmos de SVM e SVR têm por finalidade resolver problemas de classificação e regressão, respectivamente, por meio de otimização matemática.

De acordo com Noble (2006), para entender a essência do algoritmo SVM para classificação, basta compreender quatro conceitos, que serão mais bem detalhados a seguir: (I) hiperplano de separação, (II) hiperplano de margem máxima, (III) margens suaves e (IV) função kernel.

- I. Hiperplano de separação: para SVMs lineares, utilizadas para resolver problemas de classificação, a ideia geral é construir fronteiras ou retas (FIGURA 12.A) – se os dados forem linearmente separáveis – para encontrar um hiperplano que separa todos os elementos das classes (FIGURA 12.B). Um hiperplano que se configura como um plano separador dos dados é chamado de hiperplano de separação.

FIGURA 12 – ESTRUTURA DE MÁQUINA DE VETORES DE SUPORE, SENDO A. MARGENS DAS RETAS QUE DEFINEM O HIPERPLANO; B. HIPERPLANO PARA CLASSIFICAÇÃO DE DADOS LINEARES EM DUAS DIMENSÕES.



FONTE: A AUTORA (2021). ADAPTADO DE FACELI ET AL. (2011).

- II. Hiperplano de margem máxima: Uma SVM linear trabalha com a maximização da margem. Dessa forma, um hiperplano que separa o conjunto de dados sem erro, com distância entre vetores das classes opostas mais próximos a esse hiperplano, é denominado de hiperplano de margem máxima (ou de separação ótima). Nesse ponto, é importante introduzir o conceito de “margens rígidas”. São denominadas de SVMs lineares com margens rígidas as que definem fronteiras lineares para dados que são linearmente separáveis. Nestas, objetiva-se maximizar a margem de separação dos objetos, estabelecendo restrições. Essas restrições garantem que os dados de treinamento não apareçam entre as margens de separação, as quais são chamadas de margens rígidas.
- III. Margens suaves: para casos em que os dados não são linearmente separáveis, aplicam-se Máquinas de Vetores de Suporte de margens suaves, conhecidas como SVMs de margens suaves. A aplicação de SVM de margens suaves é usual, uma vez que, em situações reais, é difícil encontrar conjuntos de dados

que sejam linearmente separáveis, por conta da presença de ruídos, ou *outliers*. Nesta SVM, utiliza-se uma nova abordagem, no sentido de flexibilizar as restrições de otimização utilizando variáveis de “relaxamento” do problema, também conhecidas como “variáveis de folga”. A SVM de margens suaves permite que alguns pontos fiquem entre os planos de separação.

- IV. Função Kernel: as SVMs também podem ser utilizadas para resolver problemas não-lineares de classificação, ou seja, para dados que não podem ser separados por meio de uma linha. Para esses casos, utiliza-se uma função Kernel, a qual fornece uma solução para esse problema inserindo uma dimensão adicional para os dados, permitindo, então, sua separação (BEN-HUR; WESTON, 2010; CRISTIANINI; SHAW-ET AL., 2000).

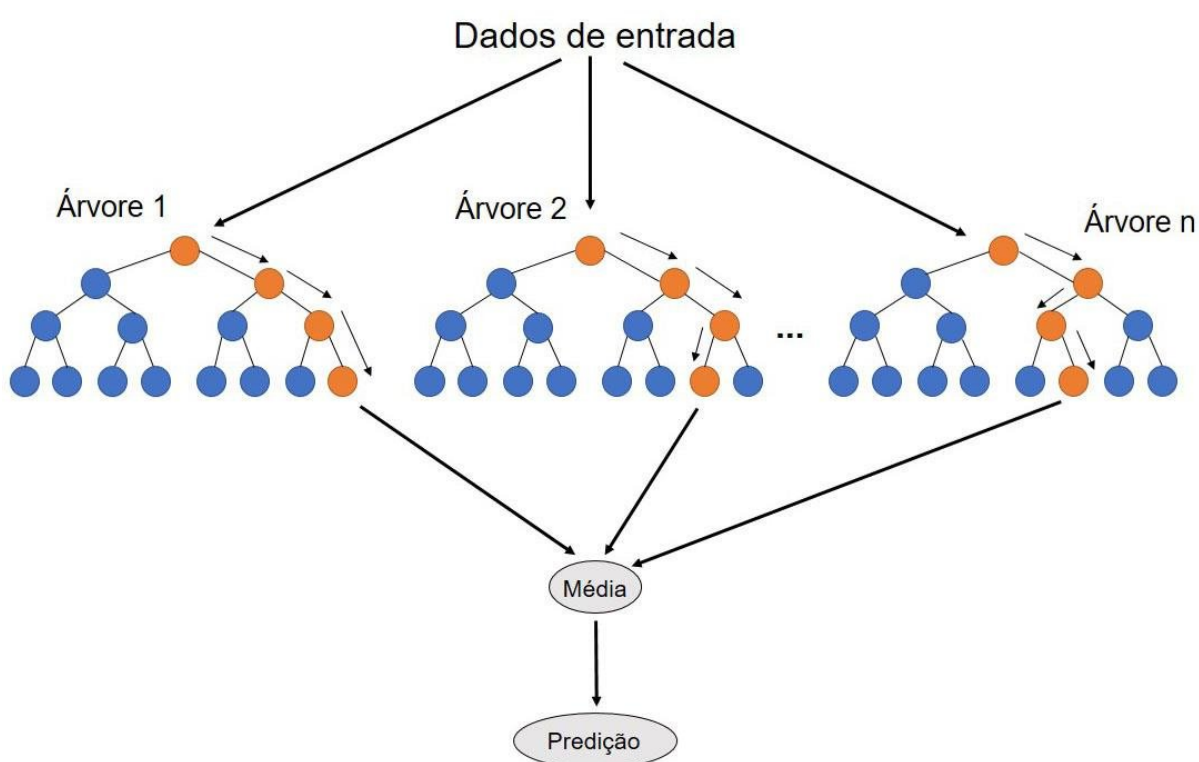
Para resolver problemas de regressão, o algoritmo de SVR mais conhecido é o ϵ -SVR, que consiste na seguinte ideia: na otimização desse algoritmo, ao invés de encontrar um hiperplano separador no espaço, encontra-se uma função $f(x)$ que tenha, no máximo, ϵ desvios para os valores reais do conjunto de treinamento, que seja o mais plana possível (SMOLA; SCHÖLKOPF, 2004; MONTAÑO, 2016; SOUZA, 2020).

d) Árvores de Regressão e Random Forest

Árvores de Decisão e Árvores de Regressão constituem-se de algoritmos preditivos de aprendizado supervisionado, os quais, baseando-se nas premissas de técnicas estatísticas, são utilizados para explorar e modelar dados (DE'ATH; FABRICIUS, 2000). São aplicados na resolução de problemas de classificação (Árvores de Decisão) e regressão (Árvores de Regressão). São assim chamados pois, uma vez que se obtêm os dados de treinamento, esses algoritmos criam a estrutura de uma árvore. As Árvore de Regressão foram propostas por Morgan; Sonquist (1963), os quais propuseram um método simples para ajustar árvores para prever uma variável quantitativa (WILKINSON, 2004), sendo que, em termos práticos, a estrutura de uma árvore de regressão é similar à árvore de classificação (BREIMAN et al., 1984).

As árvores são representadas, graficamente, no topo, com o chamado nó raiz, que representa os dados não divididos, além dos nós intermediários e os nós folha (cada nó folha representa um dos grupos finais), abaixo (DE'ATH; FABRICIUS, 2000) (FIGURA 13). O nó raiz (*root node*, em inglês) constitui o primeiro nó de decisão da árvore, e contém todas as observações do conjunto de treinamento (PUT et al., 2003). Já o nó folha (*leaf node*, em inglês), ou nó terminal, não admite divisão e, portanto, constitui a decisão final da predição, ou seja, o valor predito.

FIGURA 13 – ESTRUTURA DE UMA ÁRVORE DE REGRESSÃO.



FONTE: A AUTORA (2021).

No início dos anos 2000, foi introduzido o conceito de Random Forest, também conhecido como Floresta Aleatória, que constitui um algoritmo de aprendizado de máquina que agrupa várias árvores de modelos, treinadas a partir de um conjunto de dados para predição, de forma que o resultado final é obtido por meio da consolidação dos resultados das árvores (BREIMAN, 2001). Na realidade, o algoritmo Random Forest é um algoritmo de conjunto, mais conhecido como *ensemble*, o qual é caracterizado pela combinação de preditores fracos para gerar um preditor mais forte

(LIAW; WIENER, 2002). Dois métodos de *ensemble* bem conhecidos são o *boosting* (SCHAPIRE et al., 1998) e o *bagging* (BREIMAN, 1996).

O *ensemble* do tipo *boosting* baseia-se na premissa de atribuir um peso às amostras para, em seguida, efetuar o treinamento da base de acordo com esses pesos. Para isso, quatro etapas são seguidas: 1. Inicia atribuindo peso igual para todas as amostras; 2. Gera um classificador; 3. Aumenta o peso dos dados que foram classificados erroneamente, diminuindo o peso dos que foram corretamente classificados; 4. Gera um novo classificador. Tal processo continua até serem gerados vários classificadores. Nesse ponto, destaca-se o algoritmo “Aumento de Gradiente Estocástico” (do inglês, *Stochastic Gradient Boosting* – SGB), que concilia *boosting* e otimização (BREIMAN, 1999) e tem sido amplamente difundido, nos últimos anos, em diversas áreas de conhecimento, incluindo as Ciências Florestais (SOUZA, 2020).

2.7 DADOS ABERTOS

De acordo com o artigo 2º do Decreto nº 8.777, de 11 de maio de 2016 (BRASIL, 2016), dados abertos (*open data*) são aqueles “acessíveis ao público, representados em meio digital, estruturados em formato aberto, processáveis por máquina, referenciados na internet e disponibilizados sob licença aberta que permita sua livre utilização, consumo ou cruzamento, limitando-se a creditar a autoria ou a fonte.”

Iniciativas *open data* fazem parte de um movimento que inclui software *open-source*, hardware livre, trabalho criativo de conteúdo aberto, acesso aberto a publicações científicas e a ciência livre. De acordo com a *Open Knowledge Foundation* (disponível em: <https://okfn.org/opendata/>), as iniciativas *open data* devem seguir algumas premissas, tais como:

1. Disponibilidade e Acesso: os dados devem estar disponíveis como um todo e, preferencialmente, possíveis de serem baixados pela internet (disponibilidade de download da base de dados completa). Os dados devem também estar disponíveis em formato adequado e modificável.
2. Reutilização e Redistribuição: os dados devem ser fornecidos sob termos que permitam a reutilização e a redistribuição, inclusive a combinação com outros conjuntos de dados.

3. Participação Universal: todos devem ser capazes de usar, reutilizar e redistribuir os dados. Portanto, não deve haver discriminação contra áreas de atuação ou contra pessoas ou grupos. Dessa forma, qualquer usuário, em qualquer lugar do mundo, deve ser capaz de acessar e baixar os dados. Por exemplo, restrições de uso “não-comercial” podem impedir o uso “comercial” de determinados dados. Ou então, restrições de uso para certos fins (ex. somente para fins educativos) podem excluir ou restringir o acesso a determinados dados.

A Agenda 21, documento final da Conferência das Nações Unidas para o Meio Ambiente e Desenvolvimento (Rio-92), abordou das dificuldades no acesso e utilização dos dados produzidos pelas instituições – geralmente encontrados de forma isolada, sem padronização e em sistemas que não conversavam entre si. Na área de geotecnologia e dados espaciais, essa preocupação impulsionou o estabelecimento de acordos de compartilhamento e a construção das chamadas Infraestruturas de Dados Espaciais (IDEs), abrangendo tecnologias, políticas e padrões para aquisição, processamento, distribuição de dados geoespaciais (IBGE, 2020b).

As IDEs seguem padrões preconizados pelo *Open Geospatial Consortium* (OGC) e hoje contam com mais de 500 membros (governos, universidades e setor privado) atuando no desenvolvimento e aprimoramento de *softwares* livres e outras tecnologias para facilitar o intercâmbio de dados. No Brasil, destaque para a plataforma de da Infraestrutura Nacional de Dados Espaciais (INDE - <https://inde.gov.br/>), coordenada pelo IBGE (Instituto Brasileiro de Geografia e Estatística).

Nesse ponto, deve-se destacar a importância de iniciativas de dados abertos (*open data*) e políticas de acesso livre por parte de governos e órgãos públicos, como ocorrem em países da Europa e da América do Norte. Pode-se citar o Programa de Dados Abertos dos Estados Unidos (U.S. GOVERNMENT, 2019), o Portal de Dados Abertos do Reino Unido (U.K. GOVERNMENT, 2019) e o Programa Joinup da União Europeia (EUROPE UNION, 2020). No Brasil, destaca-se a plataforma Infraestrutura Nacional de Dados Espaciais (IBGE, 2020a), coordenada pelo IBGE (Instituto Brasileiro de Geografia e Estatística).

Destaca-se que o acesso aberto a dados científicos vem ganhando adeptos no mundo todo a partir de movimentos como o *Open Science*, uma das frentes de

atuação da *Open Knowledge International* (OPEN KNOWLEDGE FOUNDATION, 2019). A organização foi criada em 2004 e conta com iniciativas em todo o mundo, inclusive no Brasil (OPEN KNOWLEDGE BRASIL, 2019). No portal do Sistema de Bibliotecas da Universidade Federal do Paraná, são listadas algumas bases de acesso público, online e gratuito, as quais podem ser consultadas em https://portal.ufpr.br/bases_publicas.html.

No Brasil, de acordo com a Lei de Acesso à Informação - Lei nº 12.527, de 18 de novembro de 2011, os dados abertos devem ser gratuitos, acessíveis, estruturados e legíveis por máquina (BRASIL, 2011). Essa norma entrou em vigor em 16 de maio de 2012 e criou mecanismos que possibilitam, a qualquer pessoa, física ou jurídica, sem necessidade de apresentar motivo, o recebimento de informações públicas dos órgãos e entidades.

Nas ciências florestais, ressalta-se que dados brutos de inventários florestais no Brasil ainda são escassos ou se encontram de maneira dispersa em diversas bases de dados, muitas vezes com acesso restrito, limitando a realização de estudos interdisciplinares. Na floresta amazônica brasileira, essa limitação é ainda maior por conta da incipiência de trabalhos recentes conduzidos por instituições ou órgãos públicos - datados dos últimos 10 anos. Além disso, o uso dos dados existentes restringe-se a determinados órgãos governamentais ou institutos. Levando em conta que no bioma Amazônia se encontra um dos maiores estoques de biomassa e carbono do planeta (PHILLIPS et al., 2009; PAN et al., 2011; FELDPAUSCH et al., 2012), torna-se fundamental a implementação de iniciativas para disponibilidade integral de dados de vegetação.

Na área ambiental, algumas bases de dados abertos podem ser citadas, como é o caso das plataformas BDiA (Banco de Dados de Informações Ambientais), Terrabrasilis (desenvolvido pelo INPE) e SIGMA (desenvolvido pelo INPE/CPTEC). A plataforma BDiA disponibiliza, online e gratuitamente, dados obtidos pelo Projeto RADAMBRASIL, que teve duração de 15 anos (1970-1985) no âmbito do Ministério de Minas e Energia do Brasil. Algumas fontes de *open data*, de interesse acadêmico e geral, são citadas abaixo (TABELA 5).

TABELA 5 – EXEMPLOS DE FONTES DE DADOS ABERTOS (*OPEN DATA*).

Fonte	Descrição	Acesso
Governo brasileiro	Dados do Governo do Brasil	http://dados.gov.br/

IPEA	Dados do Instituto de Pesquisa Econômica Aplicada	http://www.ipeadata.gov.br
Governo dos Estados Unidos	Dados do Governo dos EUA	http://data.gov
Governo do Canadá	Dados do Governo do Canadá (em inglês e francês)	http://open.canada.ca
União Europeia	Dados da União Europeia	http://open-data.europa.eu/en/data
NASA (Agência Espacial dos Estados Unidos da América)	Dados da NASA	https://data.nasa.gov
Banco Mundial	Dados do Banco Mundial	http://data.worldbank.org
Departamento de Saúde e Serviços Humanos dos Estados Unidos	Dados sobre a saúde mundial	http://www.healthdata.gov
Quandl	Dados sobre diversas áreas de negócio e finanças	https://www.quandl.com
Google Trends	Ferramenta do Google que mostra os mais populares termos buscados em um passado recente	https://www.google.com/trends
Google Finance	É um serviço que apresenta a informações sobre empresas incluindo suas últimas decisões e também suas ações com um código em JavaScript que permite a visualização das ações no momento	https://www.google.com/finance
DBpedia	Projeto cujo objetivo é extrair conteúdo estruturado das informações da Wikipédia	http://wiki.dbpedia.org/

Open Data Monitor	Plataforma que fornece uma visão geral dos recursos de dados abertos disponíveis, permitindo que se analise e visualize catálogos de dados existentes usando tecnologias inovadoras.	http://opendatamonitor.eu
Open Data Network	Mecanismo de busca global que permite a pesquisa de dezenas de milhares de conjuntos de dados em centenas de catálogos de dados abertos	http://www.opendatanetwork.com

FONTE: A AUTORA (2021).

3 MATERIAL E MÉTODOS

3.1 BIOMA AMAZÔNIA

O bioma Amazônia possui extensão territorial de 4.196.943 km² (IBGE, 2020a), compreendendo 9 estados federativos brasileiros: Acre, Amazonas, Amapá, Rondônia, Roraima, Pará, Mato Grosso, Tocantins e Maranhão (FIGURA 14). Neste estudo, foram selecionados dados de levantamentos florestais no bioma Amazônia (parcelas de inventários florestais), a partir de duas bases de dados, as quais serão descritas nas seções 3.2.1 e 3.2.2.

FIGURA 14 – EXTENSÃO TERRITORIAL DO BIOMA AMAZÔNICO BRASILEIRO.



FONTE: A AUTORA (2021).

Na seleção das parcelas de inventários florestais, para ambas as bases de dados, não foram consideradas parcelas alocadas em florestas aluviais, ecossistemas não-florestais - tais como savanas e campinas (vegetação sobre areia branca) - ou em zonas de contato entre não-floresta e formações florestais. Também não foram consideradas parcelas alocadas no sul e no extremo oeste do bioma Amazônia, cuja ocorrência predominante de tipologias é: Contatos Florísticos, Floresta Estacional Sempre Verde, Floresta Estacional Semidecidual e Savana-Estépica, sendo estas

áreas também excluídas das análises, como pode ser observado no recorte das FIGURAS 15 e 16.

3.2 BASES DE DADOS

3.2.1 Projeto Paisagens Sustentáveis (EMBRAPA)

Os dados aqui utilizados foram extraídos do domínio do Projeto Paisagens Sustentáveis, o WebGIS Paisagens Sustentáveis Brasil, apoiado pela Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), pelo Serviço Florestal dos Estados Unidos (USFS), pela Agência dos Estados Unidos para o Desenvolvimento Internacional (USAID) e pelo Departamento de Estado dos EUA (EMBRAPA, 2014). O projeto foi criado para o desenvolvimento de novas metodologias e expansão do conhecimento através de técnicas de contabilização de carbono no âmbito do REDD+, entre eles o uso de dados LiDAR, tecnologia que permite avaliar detalhadamente áreas de estudos, fornecendo informações sobre a superfície do terreno e da estrutura da vegetação, parâmetros estes relacionados ao estoque de carbono (EMBRAPA, 2014).

O WebGIS Paisagens Sustentáveis Brasil é uma ferramenta que contém dados de inventários florestais em localidades nos biomas Amazônia, Cerrado e Mata Atlântica (<https://www.paisagenslidar.cnptia.embrapa.br/webgis/>). Esse acervo com dados de alta precisão pode ser utilizado em estudos de estrutura de floresta, cálculos de biomassa, estoque de carbono e avaliação de impactos do efeito estufa.

Ao total, foram analisados dados de 13.696 árvores. Mais detalhes sobre as áreas de estudo podem ser consultados na TABELA 6.

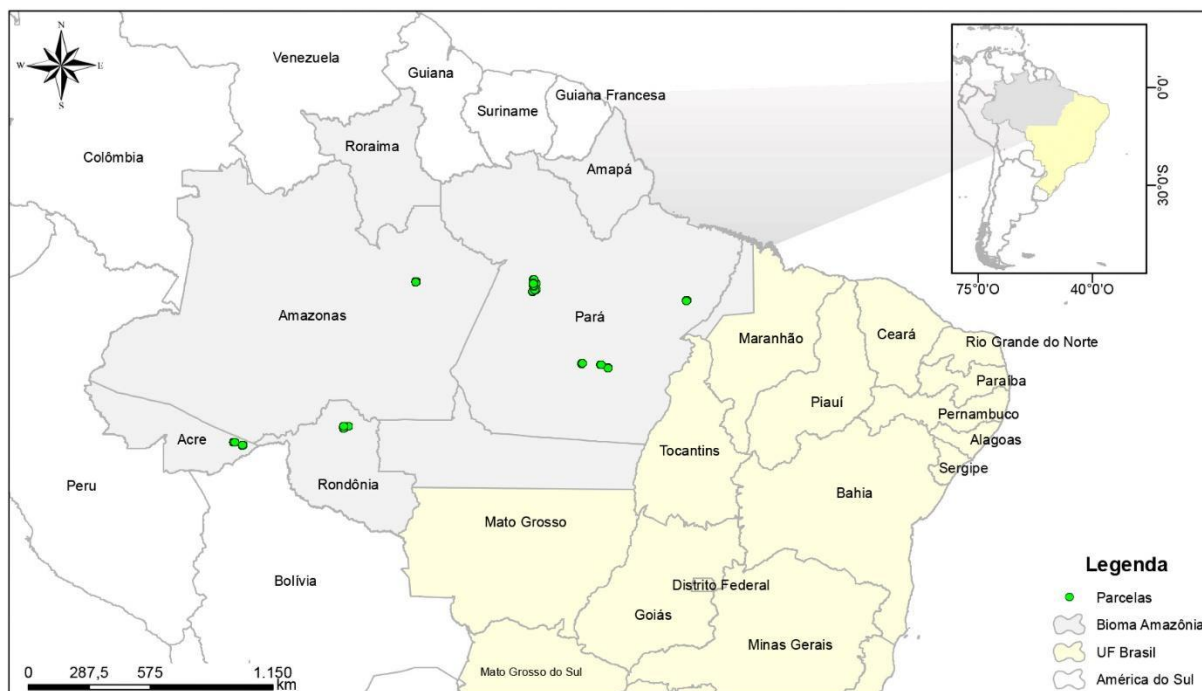
TABELA 6 – DETALHAMENTO DOS LOCAIS E Nº DE INDIVÍDUOS EXTRAÍDOS DA BASE DE DADOS DO PROJETO PAISAGENS SUSTENTÁVEIS.

Estado	Local	Ano do inventário	Nº de parcelas	Nº de árvores
Acre	Bonal, Senador Guiomar	2014	10	257
Acre	Humaitá, Porto Acre	2014	10	241
Amazonas	Reserva Ducke, Manaus	2011	5	822
Pará	Terra indígena Anambé	2015	32	3.635
Pará	Fazenda Andiroba, Paragominas	2013	20	340
Pará	Fazenda Cauaxi, Paragominas	2014	22	2.549
Pará	Paragominas	2013	10	597
Pará	Santarém, Belterra – área 1	2014	8	163
Pará	Santarém, Belterra – área 2	2014	7	177
Pará	São Félix do Xingu – área 1	2011	9	598
Pará	São Félix do Xingu – área 2	2012	22	1.610
Pará	FLONA do Tapajós – área 1	2015	9	1.071
Pará	FLONA do Tapajós – área 3	2015	10	1.078
Rondônia	FLONA do Jamari – área 2	2011	24	467
Rondônia	FLONA do Jamari – área 3	2013	4	91
		Total	202	13.696

FONTE: A AUTORA (2021).

Na base de dados aqui utilizada, com informações extraídas do WebGIS Paisagens Sustentáveis, constam medições de árvores em parcelas alocadas em 11 localidades, quatro estados do bioma Amazônia (Acre, Amazonas, Pará e Rondônia), em inventários realizados nos anos de 2011, 2012, 2013, 2014 e 2015 (FIGURA 15).

FIGURA 15 – LOCALIZAÇÃO DAS PARCELAS DO PROJETO RADAMBRASIL, EM QUATRO ESTADOS DO BIOMA AMAZÔNIA.



FONTE: A AUTORA (2021).

Classes diamétricas foram definidas, desde o menor até o maior valor de DAP (5-234 cm, para floresta densa; 10-140 cm, para floresta aberta) (TABELA 7). Dessa forma, os estoques de biomassa e carbono para dados do Projeto Paisagens Sustentáveis foram calculados para todas as classes diamétricas.

TABELA 7 – CLASSES DIAMÉTRICAS E NÚMERO DE INDIVÍDUOS POR CLASSE, EM PARCELAS NO BIOMA AMAZÔNIA. DADOS DO PROJETO PAISAGENS SUSTENTÁVEIS, DA EMBRAPA.

Classes diamétricas	Amplitude diamétrica (cm)	Nº de árvores (floresta densa)	Amplitude diamétrica (cm)	Nº de árvores (floresta aberta)
I	5-10	159	10-20	275
II	10-20	6.879	20-30	88
III	20-30	2.118	30-40	124
IV	30-40	1.337	40-50	146
V	40-50	1.143	50-60	75
VI	50-60	647	60-70	41
VII	60-70	273	70-80	26
VIII	70-80	126	80-90	7
IX	80-90	111	90-100	7
X	90-100	47	≥ 100	10
XI	≥ 100	57	-	-
	Total	12.897		799

FONTE: A AUTORA (2021).

3.2.2 Projeto RADAMBRASIL

Essa base de dados é oriunda de atividades de inventário florestal desenvolvidas ao longo do Projeto RADAMBRASIL, nos anos de 1978, 1979 e 1980, e constitui a maior base de dados de levantamentos florestais até hoje registrada para a Amazônia brasileira. Os dados foram extraídos da plataforma digital BDIA - de acesso livre e disponível em <https://bdiaweb.ibge.gov.br/> - desenvolvida pelo Instituto Brasileiro de Geografia e Estatística (IBGE). O BDIA contém informações coletadas no âmbito do Projeto RADAMBRASIL, divididas em quatro áreas temáticas: Geologia, Geomorfologia, Pedologia e Vegetação (IBGE, 2020a). Na plataforma BDIA, dados de 25 volumes publicados pelo Projeto estão disponibilizados online, de tal forma que o usuário pode acessar e compartilhar, de forma interativa, o acervo de informações ambientais do IBGE (IBGE, 2020a).

Os dados brutos de inventário florestal (denominado de “Pontos de amostragem”) contêm as seguintes informações: ID da parcela; família; autor que descreveu a família; classe comercial; aspecto do fuste; volume da madeira; circunferência a 1,30 m de altura de cada árvore (CAP), para indivíduos com CAP \geq 95 cm (ou diâmetro a 1,30 m de altura - DAP \geq 30 cm). Além disso, contém informações da tipologia florestal, localização, descrição das áreas, entre outras, para cada parcela.

Foram selecionados dados de levantamentos florestais na Amazônia, totalizando 114.231 indivíduos, distribuídos em 2.012 parcelas (1.158 em floresta densa; 854 em floresta aberta) abrangendo o bioma Amazônia em 9 estados brasileiros, sendo estes: Acre, Amapá, Amazonas, Maranhão, Mato Grosso, Pará, Rondônia, Roraima e Tocantins (TABELA 8). As tipologias avaliadas foram: Floresta Ombrófila Densa e Floresta Ombrófila Aberta. Portanto, a base de dados final contém as seguintes informações: local da parcela (estado); identificação da parcela (ID); latitude ($^{\circ}$ ' "); longitude ($^{\circ}$ ' "), família; espécie; e DAP (em cm), após a divisão dos valores de CAP por π .

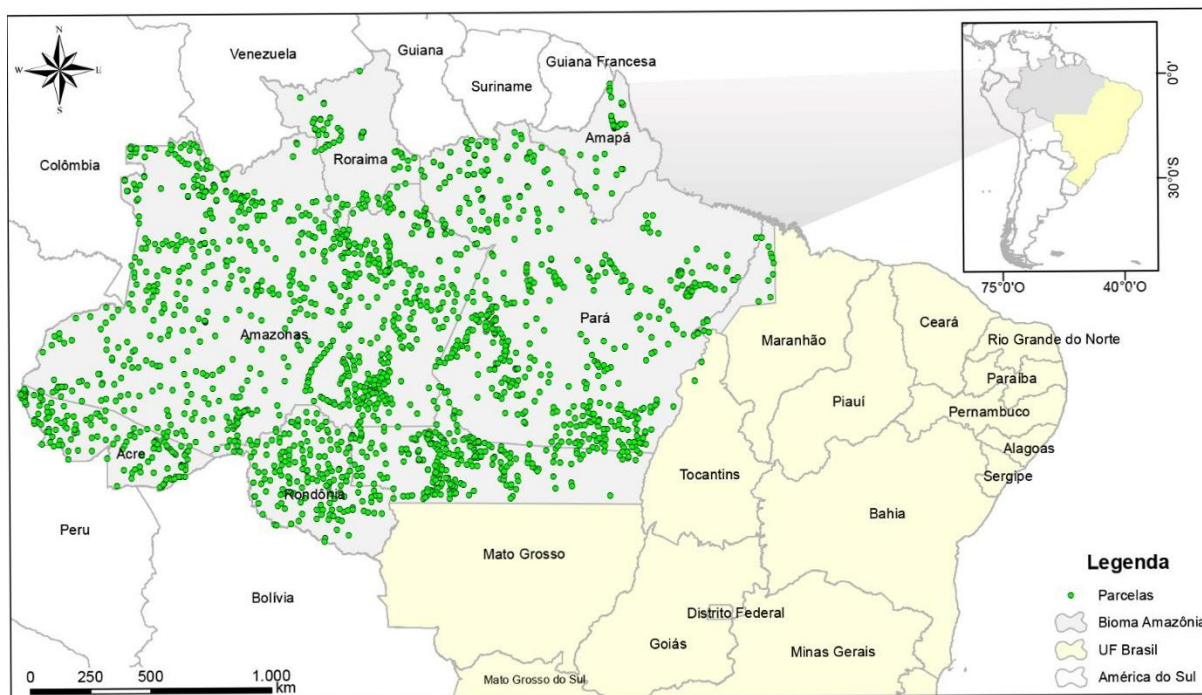
TABELA 8 – DETALHAMENTO DOS LOCAIS, PARCELAS E Nº DE INDIVÍDUOS EXTRAÍDOS DA BASE DE DADOS DO PROJETO RADAMBRASIL.

Estado	Nº de parcelas	Nº de árvores
Acre	143	8.156
Amapá	35	2.609
Amazonas	788	48.703
Maranhão	10	602
Mato Grosso	309	15.299
Pará	491	25.608
Rondônia	168	9.421
Roraima	62	3.627
Tocantins	6	206
Total	2.012	114.231

FONTE: A AUTORA (2021).

Dados vetoriais de todos os pontos de amostragem de inventário do Projeto RADAMBRASIL também foram extraídos via plataforma BDIA. Arquivos no formato *shapefile* dos estados da Amazônia brasileira foram baixados. Desses arquivos, coordenadas UTM (*Easting and Northing*) de cada parcela de inventário florestal foram extraídas. As coordenadas UTM foram convertidas para coordenadas geográficas para fins de padronização de sistema. As localizações de cada uma das 2.012 parcelas de inventário abordadas neste estudo podem ser observadas abaixo (FIGURA 16).

FIGURA 16 – LOCALIZAÇÃO DAS PARCELAS DO PROJETO RADAMBRASIL, EM 9 ESTADOS QUE COMPÕEM O BIOMA AMAZÔNIA, NA FLORESTA AMAZÔNICA BRASILEIRA.



FONTE: A AUTORA (2021).

Classes diamétricas foram definidas em intervalos de 10 cm, desde o menor até o maior valor de DAP (30-305 cm) (TABELA 9). Dessa forma, os estoques de biomassa e carbono para dados do Projeto RADAMBRASIL foram calculados para todas as classes diamétricas.

TABELA 9 – CLASSES DIAMÉTRICAS E NÚMERO DE INDIVÍDUOS POR CLASSE, EM PARCELAS NO BIOMA AMAZÔNIA. DADOS DO PROJETO RADAMBRASIL.

Classes diamétricas	Amplitude diamétrica (cm)	Nº de árvores (floresta densa)	Nº de árvores (floresta aberta)
I	30-40	28.737	18.054
II	40-50	19.010	11.332
III	50-60	10.172	6.371
IV	60-70	5.476	3.481
V	70-80	3.389	2.129
VI	80-90	1.367	919
VII	90-100	896	619
VIII	100-110	410	323
IX	110-120	308	222
X	120-130	229	175
XI	130-140	92	62
XII	140-150	101	72
XIII	≥ 150	184	101
	Total	70.371	43.860

FONTE: A AUTORA (2021)

3.2.3 Projeto Paisagens Sustentáveis (EMBRAPA): base de dados para comparação de estoques de biomassa obtidos por meio de equações de biomassa, dados LiDAR e algoritmos de aprendizado de máquina

Além de conter dados de inventários florestais em 17 localidades no bioma Amazônia, o WebGIS Paisagens Sustentáveis Brasil é uma ferramenta que torna disponível o maior acervo de dados do Brasil provenientes de levantamentos realizados com a tecnologia LiDAR (*Light Detection and Ranging*), sistema de varredura *laser*. A base de dados apresentada a seguir foi utilizada para fins de comparação entre as técnicas LiDAR, algoritmos de aprendizado de máquina e regressão linear nas estimativas de biomassa e carbono (TABELA 10).

TABELA 10 – DETALHAMENTO DA BASE DE DADOS UTILIZADA PARA COMPARAÇÃO DAS ESTIMATIVAS DE BIOMASSA OBTIDAS POR MEIO DE EQUAÇÕES DE BIOMASSA, DADOS LIDAR E ALGORITMOS DE APRENDIZADO DE MÁQUINA. LOCALIDADE: FAZENDA CAUAXI, PARAGOMINAS, PARÁ. DADOS EXTRAÍDOS DO PROJETO PAISAGENS SUSTENTÁVEIS DA EMBRAPA.

Estado	Local	Ano do inventário	Nº de transectos	Nº de árvores
Pará	Fazenda Cauaxi, Paragominas	2012	22 (1 ha, cada)	2.308

FONTE: A AUTORA (2021)

Em todas as parcelas inventariadas, há registro de DAP (em cm) e altura total (em m) das árvores. Além disso, valores de densidade básica da madeira, de acordo com valores disponíveis na literatura (FEARNSIDE, 1997b; NOGUEIRA; NELSON; FEARNSIDE, 2005; NOGUEIRA et al., 2007), foram encontrados para cada espécie arbórea ocorrente na área (170, no total), para fins de aplicação do modelo pantropical de Chave et al. (2014) nas estimativas de biomassa por indivíduo. Os valores de densidade básica da madeira (g cm^{-3}) por espécie constam no APÊNDICE 1.

Os dados LiDAR referem-se ao sobrevoo realizado na área, no ano de 2013, abrangendo uma área de 500 ha. Na TABELA 11, é possível observar os parâmetros do sobrevoo para coleta das nuvens LiDAR:

TABELA 11 – ESPECIFICAÇÕES TÉCNICAS DO SOBREVOO REALIZADO NA ÁREA DA FAZENDA CAUAXI PARA COLETA DAS NUVENS LIDAR. DADOS EXTRAÍDOS DO PROJETO PAISAGENS SUSTENTÁVEIS DA EMBRAPA.

Especificações	Detalhamento
Data do sobrevoo	27/07/2012 a 29/07/2012
Datum	Sirgas 2000
Sistemas de Coordenadas	UTM
Zona	22S
Área total	1.214 ha
Densidade média de pulsos por metro quadrado	28,3 ppm ²
Altitude média de voo	850 m
Campo de visão	11°
Modelo do <i>scanner</i>	ALTM 3100
Frequência de varredura	59,8 Hz
Porcentagem de sobreposição	65%

FONTE: PROJETO PAISAGENS SUSTENTÁVEIS – EMBRAPA.

Mais detalhes com relação ao processamento dos dados LiDAR podem ser encontrados em REX (2019, seção 5.3.3). Neste trabalho, dados LiDAR e Modelos Digitais do Terreno (MDT) foram processados com auxílio do software FUSION versão 3.60 (MCGAUGHEY, 2016), desenvolvido pelo Serviço Florestal Norte Americano. Em seguida, gerou-se o Modelo Digital de Altura (em inglês, *Canopy Height Model* – CHM) para extração das métricas LiDAR por parcela.

3.3 PROCESSO DE KDD

O processo de KDD tem por objetivo transformar os dados brutos em dados úteis para os pesquisadores (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996).

Portanto, tem como meta principal a transformação de dados em conhecimento. As principais etapas do processo de KDD consistem na seleção de dados, pré-processamento e limpeza, transformação, Mineração de Dados (etapa principal em que a extração de informações úteis é efetivamente realizada por meio de diversas técnicas, principalmente as técnicas de Inteligência Artificial), interpretação e avaliação e, por fim, obtenção do conhecimento. A descrição das etapas do processo de KDD aplicados às bases de dados utilizados no presente trabalho será explicada a seguir.

1. Seleção dos dados

A primeira etapa consistiu na seleção dos dados de inventário florestal para todos os estados que compõe o bioma Amazônia via plataforma BDiA e plataforma WebGIS Paisagens Sustentáveis Brasil. Posteriormente, os dados brutos (denominados de “Pontos de Amostragem”) foram exportados no formato de planilha eletrônica, extensão “.xls”, contendo as seguintes informações: ID da parcela; família; autor que descreveu a família; classe comercial; aspecto do fuste; volume da madeira; circunferência à altura do peito de cada árvore (CAP), para indivíduos com $CAP \geq 95$ cm (ou $DAP \geq 30,24$ cm), para dados da plataforma BDiA, indivíduos com $DAP \geq 5$ cm, para dados da plataforma WebGIS. Ademais, as planilhas de dados brutos contêm informações da tipologia florestal, localização, descrição das áreas, entre outras, para cada parcela.

Os dados vetoriais de cada parcela foram obtidos a partir do download dos *shapefiles* de cada estado do bioma Amazônia. A partir da análise da tabela de atributos de cada *shapefile*, utilizando do software ArcGIS versão 10.5. (ESRI, 2020), foram extraídas informações das coordenadas UTM (*Easting and Northing*) para as 2.012 parcelas de inventário florestal.

2. Pré-processamento e limpeza

Teve por objetivo explorar os dados brutos até a obtenção dos dados de interesse. Para isso, realizou-se a eliminação de dados ausentes, outliers e dados incompletos. Nessa etapa, foram utilizados o software Microsoft Excel© e ambiente

estatístico R (R CORE TEAM, 2019). Além disso, selecionaram-se apenas dados para os quais havia correspondência de dados vetoriais, ou seja, dados de coordenadas UTM. Como descrito na seção 3.3.2 (TABELA 8) bases de dados finais ficaram extensivas, contendo as seguintes informações: local da parcela (estado); identificação da parcela (ID); latitude ($^{\circ}$ ' "); longitude ($^{\circ}$ ' "), família; espécie; e DAP (em cm), após a divisão dos valores de CAP por π .

3. Transformação

Algumas vezes, certos atributos devem ser transformados para que sejam entradas corretas em certos algoritmos ou equações. Nessa etapa, os valores de DAP, em cm, foram obtidos após a conversão do CAP em DAP, ou seja, divisão dos valores de CAP por π . Por fim, as variáveis foram log-transformadas, para fins de inserção das variáveis em equações logarítmicas.

4. Mineração de dados

Em parte da literatura relacionada, a mineração de dados é tratada como sinônimo de processo KDD, como explicam Faceli et al. (2011, capítulo 26). Entretanto, outros autores, como Fayyad; Piatetsky-Shapiro; Smyth (1996), consideram a mineração de dados uma etapa no processo de KDD. No presente trabalho, será considerada a definição proposta por Fayyad; Piatetsky-Shapiro; Smyth (1996).

Cabe ressaltar que, nesta etapa, técnicas de diversas áreas do conhecimento podem ser usadas: estatística, métodos numéricos, técnicas de Inteligência Artificial, entre outras. As técnicas mais usadas atualmente para essa fase são as técnicas de Aprendizagem de Máquina, ramo da Inteligência Artificial em que os algoritmos aprendem com os dados e conseguem fazer previsões, agrupamentos e regras de associação. Em particular, o aprendizado poder ser feito usando Redes Neurais Artificiais (RNA), Máquinas de Vetores de Suporte (SVM), Máquinas de Vetores de Regressão (SVR), Random Forest, entre outras técnicas.

No presente trabalho, analisou-se a distribuição dos dados e aplicação de testes de normalidade. Por meio de estatística descritiva, foram calculados e analisados os valores máximos e mínimos, média aritmética, desvio padrão e

variância dos dados. Todas as análises foram realizadas no software R[®] (R CORE TEAM, 2019).

Ademais, compararam-se estimativas de biomassa por meio de duas técnicas de aprendizado de máquina (ANN e Random Forest) com a equação pantropical de Chave et al. (2014) e equação com métricas LiDAR, em parcelas de inventário na Amazônia, com dados presentes na base do Projeto Paisagens Sustentáveis, da EMBRAPA, como explanado na seção 3.1.3, acima.

5. Interpretação e Avaliação

Nessa etapa, foram analisados os valores estimados de biomassa e carbono nas parcelas de inventário florestal, buscando reconhecer padrões para, posteriormente, discutir suas implicações, de acordo com os objetivos da tese de doutorado.

6. Conhecimento

Obtenção da base de dados final, para atender ao principal objetivo do estudo: estimar os estoques de biomassa e carbono para cada parcela de inventário florestal, a partir de equações de biomassa desenvolvida para ambientes tropicais. Os resultados da tese foram integrados ao software JCarbon[®] (WOJCIECHOWSKI, 2015). Assim, qualquer usuário do Brasil e do mundo poderá, livre e gratuitamente, acessar e compartilhar todas as informações de estoques de biomassa e carbono relatadas no presente trabalho.

3.4 EQUAÇÕES DE BIOMASSA

Os valores de biomassa seca acima do solo foram quantificados a partir de equações de biomassa (método indireto) ajustadas para o ecossistema Amazônia. Uma vez que as equações de Higuchi et al. (1998) e Silva (2007) estimam a biomassa verde, foi necessária a adoção de um fator de conversão de massa verde para massa seca. A conversão consistiu na multiplicação da biomassa estimada por meio dessas duas equações por 0,57. Esse procedimento foi proposto em Silva (2007, TABELA 5.8c), considerando que 43% do peso representa a quantidade de água, e 57% seriam, de fato, o peso seco de biomassa. Ao total, cinco equações foram selecionadas (TABELA 12):

TABELA 12 – EQUAÇÕES DE BIOMASSA UTILIZADAS NAS ESTIMATIVAS DE BIOMASSA ACIMA DO SOLO (BAS).

Local	Equações	Autor
Floresta Ombrófila Densa	$w = (\exp(-0,151 + 2,17 \times \ln(DAP))) \times 0,57$ (7)	Higuchi et al. (1998)
Floresta Ombrófila Densa	$w = \exp(-0,37 + 0,333 \times \ln(DAP) + 0,933 \times \ln(DAP)^2 - 0,122 \times \ln(DAP)^3)$ (8)	Chambers et al. (2001)
Floresta Ombrófila Densa	$w = (2,2737 \times DAP^{1,9156}) \times 0,57$ (9)	Silva (2007)
Floresta Ombrófila Aberta	$w = \exp(-1,716 + 2,413 \times \ln(DAP))$ (10)	Nogueira et al. (2008) Equação 1
Floresta Ombrófila Aberta	$w = \exp(-1,929 + 2,335 \times \ln(DAP))$ (11)	Nogueira et al. (2008) Equação 2

Em que: w = biomassa seca acima do solo, em $Mg\ ha^{-1}$; DAP = diâmetro à altura do peito (1,3 m), em centímetros. Nota: os parâmetros estatísticos das equações utilizadas são os seguintes: 1. Higuchi et al. (1998): $R^2 = 0,90$; 2. Chambers et al. (2001): $R^2 = 0,973$; $MSE = 0,297$; 3. Silva (2007): $R^2 = 0,94$; $S_{yx} = 3,9\%$. Nogueira et al. (2008) Equação 1: $R^2 = 0,964$; $S_{yx} = 0,306$. Nogueira et al. (2008) Equação 2: $R^2 = 0,949$; $S_{yx} = 0,359$. R^2 = coeficiente de determinação; S_{yx} = erro padrão da estimativa, em porcentagem; MSE = Erro quadrático médio.

Foram escolhidas apenas equações de biomassa que utilizam o DAP como variável independente, devido a sua facilidade de obtenção em inventários florestais na floresta amazônica. Equações que utilizam a altura total como variável independente foram descartadas, uma vez que é uma variável considerada de difícil obtenção, devido à alta densidade de árvores (nº de indivíduos por unidade de área) na floresta amazônica. Outras equações de biomassa encontradas na literatura, que utilizam como variável independente a densidade da madeira, também foram evitadas, uma vez que seu valor varia muito entre as espécies arbóreas tropicais (NOGUEIRA et al., 2008). Os valores obtidos por meio das equações, em kg, foram divididos por mil, de tal forma a se obter os valores em Mg.

Para as equações de floresta aberta, ressalta-se que a Equação 1 de Nogueira

et al. (2008) foi ajustada para a obtenção do peso seco de biomassa da “árvore inteira” (fuste, copa e galhos). Com relação à Equação 2, esta foi ajustada, para o mesmo conjunto de dados ($n = 262$), para a obtenção apenas do peso seco do fuste.

Além das cinco equações supracitadas, duas equações de biomassa desenvolvidas por Brown (1997), genéricas para florestas tropicais, ou seja, que englobam diversas tipologias florestais, foram aplicadas aos dados de todas as parcelas, para fins de comparação com os resultados obtidos para as equações de biomassa específicas de floresta densa e floresta aberta (TABELA 13):

TABELA 13 – EQUAÇÕES DE BIOMASSA AJUSTADAS POR BROWN (1997), PARA ESTIMAÇÃO DA BIOMASSA EM FLORESTAS TROPICAIS.

Equações	Autor
$w = 42,69 - 12,8 \times DAP + 1,242 \times DAP^2$ (12)	Brown (1997) Equação 1
$w = \exp(-2,134 + 2,53x \ln(DAP))$ (13)	Brown (1997) Equação 2

FONTE: A AUTORA (2021).

O cálculo do carbono estocado, em megagramas (Mg), foi realizado a partir dos valores de biomassa, de acordo com equação recomendada pelo Painel Intergovernamental sobre Mudanças Climáticas (IPCC, 2006):

$$C = w * TC = w * 0,48 \quad (14)$$

Em que: C = carbono, em megagramas; w = biomassa, em megagramas; TC = teor de carbono. A concentração de carbono na vegetação amazônica está em torno de 48% (HIGUCHI; CARVALHO JR, 1995), valor este que está dentro dos limites de concentrações em florestas tropicais (entre 46 e 52%). Portanto, o teor de carbono aplicado na fórmula foi de 0,48.

Também foram estimadas as possíveis emissões de CO_2 na atmosfera, ou seja, a quantidade de dióxido de carbono emitida na hipótese de que haja um desmatamento seguido de queimada nas florestas analisadas neste estudo. Nesse caso, utiliza-se o termo CO_{2eq} (dióxido de carbono equivalente). Para estimar as emissões em CO_{2eq} , os estoques de carbono foram convertidos por estequiometria, considerando as massas atômicas $C = 12$, $O = 16$, e massa molecular $CO_2 = 44$ (IPCC, 2006).

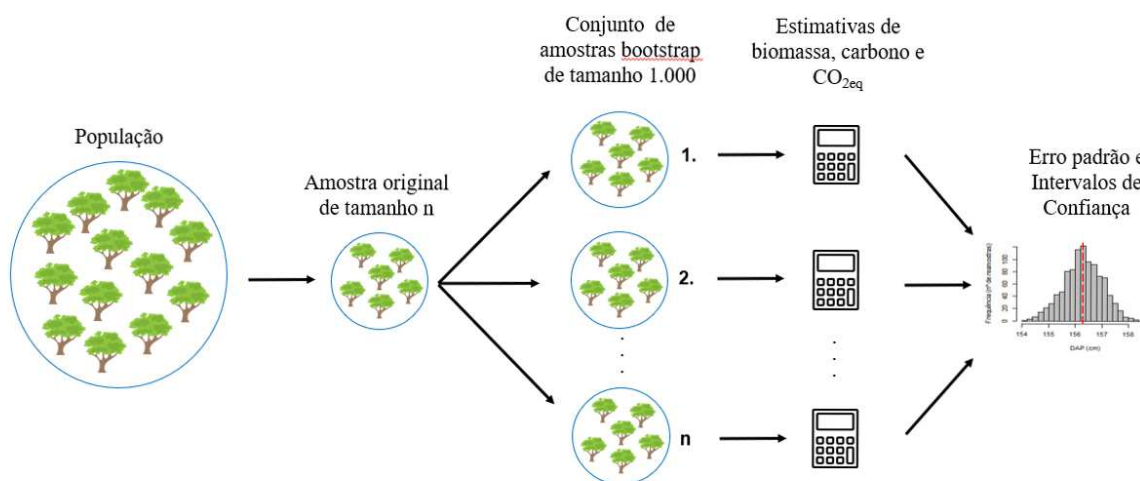
$$CO_{2eq} = C * \frac{44}{12} \quad (15)$$

Em que: CO_{2eq} = dióxido de carbono equivalente, em megagramas; C = carbono, em megagramas.

3.4.1 MÉTODO BOOTSTRAP

Bootstrapping é uma técnica de reamostragem na qual um grande número de amostras do mesmo tamanho é extraído, repetidamente e com reposição, de uma única amostra original (EFRON, 1979). Nesse estudo 1.000 amostras bootstrap foram extraídas das amostras originais, para dados do Projeto Paisagens Sustentáveis (seção 3.1.1) e para dados do Projeto RADAMBRASIL (seção 3.1.2) (FIGURA 17). Para cada reamostragem, foram calculados os estoques de biomassa, considerando cada uma das equações e classes de DAPs.

FIGURA 17 – PROCEDIMENTO DE REAMOSTRAGEM BOOTSTRAP, APLICADA AOS DADOS DE INVENTÁRIO FLORESTAL DO PROJETO RADAMBRASIL E DO PROJETO PAISAGENS SUSTENTÁVEIS NO BIOMA AMAZÔNIA.



FONTE: A AUTORA (2021).

Os passos do algoritmo bootstrap são descritas abaixo:

Passo 1. Para os dados do Projeto Paisagens Sustentáveis, contar o número de árvores (n_{classe}) por classe diamétrica;

Passo 2. Para cada classe diamétrica, selecionar aleatoriamente, com reposição, n_{classe} árvores e seus respectivos valores de DAP;

Passo 3. Para cada classe de dap, utilizar as equações das Tabelas 12 e 13 para estimar a biomassa, carbono e CO₂eq das árvores selecionadas na etapa anterior;

Passo 4. Para cada classe de DAP, calcular a média da biomassa estimada das n_{classe} árvores;

Passo 5. Replicar Passos 2–4 mil (1.000) vezes;

Passo 6. Para cada classe de DAP, calcular erro padrão (Eq. 16) e intervalo de confiança das médias replicadas (Passos 4–5).

Passo 7. Repetir Passos 1–6 para o segundo os dados do Projeto RADAMBRASIL.

As estimativas bootstrap para média e erro padrão da biomassa estimada foram calculadas a partir das seguintes fórmulas (EFRON, 1979; STĘPIEŃ, 2016):

$$\bar{\theta}_B = \frac{1}{B} \sum_{i=1}^B \hat{\theta}_B \quad (16)$$

$$\hat{s}_B = \sqrt{\frac{\sum_{b=1}^B (\bar{\theta}_B - \hat{\theta}_B)^2}{B-1}} \quad (17)$$

Intervalos de confiança (95%) foram calculados para cada classe diamétrica, com o objetivo de identificar-se em quais classes há diferenças na distribuição da biomassa estimada de acordo com a escolha da equação alométrica. Todos os cálculos foram realizados no software R (R CORE TEAM, 2019). O pacote ggplot2 (WICKHAM, 2016) foi utilizado na elaboração dos gráficos.

3.5 COMPARAÇÃO DE ESTOQUES DE BIOMASSA OBTIDOS POR MEIO DE EQUAÇÕES DE BIOMASSA, DADOS LIDAR E ALGORITMOS DE APRENDIZADO DE MÁQUINA

Para o conjunto de dados apresentado na seção 3.1.3, a biomassa aérea foi estimada a partir das equações de biomassa (regressão linear), modelos de aprendizado de máquina e estimativas com métricas LiDAR.

As estimativas de biomassa a partir do método de regressão linear foram calculadas utilizando o modelo pantropical, desenvolvido por Chave et al. (2014):

$$w = 0,0673 (\rho \text{ DAP}^2 ht)^{0,976} \quad (18)$$

Em que: w = biomassa, em quilogramas; DAP = diâmetro à altura do peito (1,3 m), em centímetros; ht = altura total da árvore, em metros; ρ = densidade básica da madeira, em g cm^{-3} .

Para estimativas de biomassa a partir de modelos de aprendizado de máquina, utilizou-se a aplicação web MLMBio, desenvolvida por Souza et al. (2020) a partir do pacote 'Shiny' (CHANG et al., 2020), o qual constitui um *framework* para construção de aplicações web em linguagem R. A partir dessa aplicação web é possível estimar a biomassa aérea total de árvores em florestas tropicais com modelos de aprendizado de máquina.

A aplicação web MLMBio foi desenvolvida para disponibilizar equações a partir de dois modelos acurados de aprendizado de máquina para estimar a biomassa aérea em ambientes tropicais: Modelo ANN (com nove neurônios na camada oculta e uma taxa de decaimento de pesos igual a 0,2) e Modelo Random Forest do tipo Stochastic Gradient Boosting (1.500 árvores, cada uma com 5 divisões - ou seis nós terminais, com um número mínimo de cinco observações por nó terminal, e uma taxa de aprendizado de 0,01) (SOUZA, 2020). Os modelos foram ajustados ao conjunto de dados completo utilizado por Chave et al. (2014) ao desenvolver seu modelo pantropical ($n = 4.004$). O aplicativo web MLMBio pode ser acessado no seguinte endereço: <https://deivisonsouza.shinyapps.io/MLBiomass/>.

Após a extração das métricas LiDAR, detalhada na seção 3.2.3, as variáveis “Retornos do primeiro quartil (P25)” e “Variação da elevação (Var)” foram consideradas para cálculo das estimativas de biomassa por parcela (Mg ha^{-1}), por meio da seguinte equação, desenvolvida por d'Oliveira et al. (2012):

$$w = (3,119 + 0,564 P25 + 0,062 Var)^2 + 1,74 \quad (19)$$

Em que: w = biomassa acima do solo, em Mg ha^{-1} , $P25$ = retornos do primeiro quartil ou 25% percentil, Var = variação da elevação.

Além dos modelos de ANN e de Random Forest, inclusos no aplicativo web MLMBio, também foram avaliadas, para este mesmo conjunto de dados, estimativas de biomassa para sete modelos de aprendizado de máquina testados por Souza (2020) e que apresentaram melhores desempenhos. Estes algoritmos foram treinados a partir do conjunto de dados para florestas tropicais de Chave et al. (2014). Os modelos testados, bem como os hiperparâmetros ótimos, estão especificados abaixo (TABELA 14):

TABELA 14 – ALGORITMOS DE APRENDIZADO DE MÁQUINA, EPECIFICADOS DE ACORDO COM A CONFIGURAÇÃO ÓTIMA DE HIPERPARÂMETROS.

Modelo	Hiperparâmetro
SVR (Radial)	sigma = 0,05 decay = 2
XGBoost	rounds = 500 eta = 0,05 max_depth = 2
M5'	pruned = yes smoothed = no
wkNN	k = 66 kernel = triweight d = 1
RF	mtry = 1 ntree = 500
BT	nbagg = 200
RT	cp = 0,00016

FONTE: A AUTORA (2021).

Em que: SVR = Support Vector Regression; XGBoost = Extreme Gradient Boosting; M5' = Model Tree; wkNN = Weighted k-Nearest-Neighbor; RF = Random Forest; BT = Bagged Trees;

RT = Regression Trees.

3.6 INTEGRAÇÃO COM O SOFTWARE JCARBON®

Os resultados do presente trabalho (estimativas de biomassa e coordenadas geográficas de cada parcela) foram integrados ao software JCarbon®, desenvolvido e criado por Wojciechowski (2015). O software JCarbon®, programado em linguagem Java, é um sistema para auxiliar nas estimativas de volume, biomassa e carbono em diversas tipologias florestais (WOJCIECHOWSKI, 2015). Os dados disponibilizados no JCarbon® podem ser acessados, livre e gratuitamente, no sítio <http://www.jcarbon.ufpr.br>.

A linguagem Java foi escolhida por atender ao paradigma orientado a objetos, característica do JCarbon®, e por ser difundida no mercado de desenvolvimento de software, utilizada por empresas de todo o mundo (ORACLE, 2020). O JCarbon® possui 10 métodos para realização das estimativas de volume, biomassa e carbono. Além desses métodos, é possível calcular a biomassa e carbono utilizando uma equação de conversão a partir do volume. A utilização de cada um dos métodos depende dos dados de entrada disponíveis ao usuário.

Esse *software* possui um banco de dados capaz de armazenar informações de locais cadastrados, os quais podem ser visualizados espacialmente com o Google Maps®. Tais informações compreendem, além dos dados básicos dos locais como localização, dimensões das árvores, equações e modelos utilizados para os cálculos, os valores totais de biomassa e carbono calculados automaticamente. Além disso, baseando-se nas premissas de *open data*, a integração com o software JCarbon® permite que usuários de qualquer localidade possam acessar e compartilhar as informações de estoques de biomassa e carbono relatadas no presente trabalho.

3.7 MAPAS DE BIOMASSA E CARBONO

Os mapas foram gerados a partir da interpolação dos valores de biomassa e carbono das parcelas pelo método de inverso da distância ponderada (IDW) no software ArcGIS versão 10.5. (ESRI, 2020). Para tanto utilizou-se o peso potência igual a 1 para a biomassa e carbono, com 6 e 12 vizinhos próximos, para o mínimo e máximo, respectivamente. O IDW consiste na espacialização de uma variável, com

base na média ponderada dos n vizinhos mais próximos, ponderando pesos a cada um dos vizinhos, de tal maneira que quanto mais próximo o vizinho, maior o peso atribuído (ZIMMERMAN et al., 1999; YASREBI et al., 2009; RAHMAN; ALIREZA; REZA, 2010). Esse método é um dos mais comuns para a interpolação de amostras, devido a sua simplicidade e estimativas confiáveis para grandes amostras, além de favorecer a estimativa para locais não amostrados, com base nas parcelas do inventário florestal (LIU et al., 2014).

A área do bioma Amazônia considerada foi determinada em função da distribuição das parcelas de inventário florestal, para minimizar os possíveis erros na interpolação. Portanto, removeram-se as áreas de savanas, campinas, campinaras, zonas de contato entre não-floresta e formações florestais e hidrografia, filtrando-se apenas áreas cobertas pelas fitofisionomias floresta aberta e floresta densa (<https://bdiaweb.ibge.gov.br/#/consulta/vegetacao>, Recorte: bioma Amazônia). Dessa forma, a área resultante foi de 2.863.672,31 km².

Também foram gerados mapas de biomassa e carbono a partir de valores de biomassa aérea expandida. Ou seja, foram utilizados fatores de expansão de biomassa para inclusão da biomassa de árvores com DAPs entre 10 e 30 cm. Os valores de fatores de expansão foram retirados do relatório do Terceiro Inventário Brasileiro de Emissões e Remoções de GEEs (MCTI, 2015), sendo estes: FEB = 1,537 (tipologia floresta densa); FEB = 1,506 (tipologia floresta aberta).

4 RESULTADOS E DISCUSSÃO

4.1 ESTIMATIVAS DE BIOMASSA E CARBONO PARA DADOS DO PROJETO PAISAGENS SUSTENTÁVEIS (EMBRAPA)

4.1.1 Distribuição diamétrica

A descrição da base de dados do Projeto Paisagens Sustentáveis, utilizada para calcular os estoques de biomassa por meio de equações de biomassa ($n = 13.696$ árvores), está apresentada na TABELA 15, abaixo:

TABELA 15 – DESCRIÇÃO DA BASE DE DADOS DO PROJETO PAISAGENS SUSTENTÁVEIS DA EMBRAPA, PARA A VARIÁVEL DIÂMETRO À ALTURA DO PEITO.

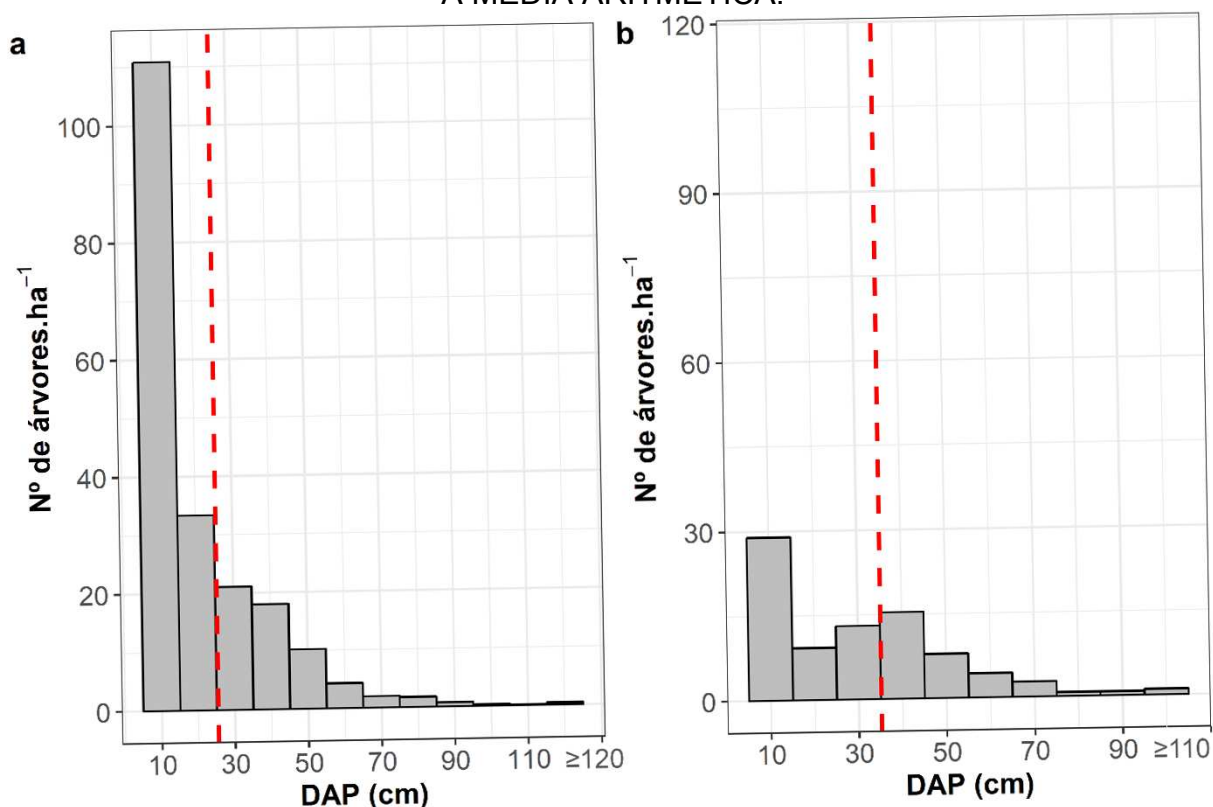
Variável	Valor mínimo	Valor máximo	Média	Desvio padrão
Diâmetro à altura do peito (cm)	5,0	240,0	25,49	18,27

FONTE: A AUTORA (2021)

A distribuição diamétrica dos indivíduos arbóreos para floresta densa segue o padrão decrescente, em forma de “J invertido” (FIGURA 18). Os DAPs das árvores concentraram-se entre 10-30 cm, com um total de 9.181 indivíduos, o que representa, aproximadamente, 71% de indivíduos em parcelas de floresta densa (FIGURA 18.A). A média de DAP para indivíduos de floresta densa foi igual a 25,45 cm.

Para dados de floresta aberta, o mesmo padrão de distribuição “J invertido” pode ser observado (FIGURA 18.B). Os DAPs dos indivíduos concentraram-se entre 10-50 cm (634 indivíduos, que representam 79% do total), sendo que os intervalos 10-20 cm e 40-50 concentraram o maior número de indivíduos, 279 e 147, respectivamente. A média de DAP para indivíduos de floresta densa foi igual a 35,1 cm.

FIGURA 18 – DISTRIBUIÇÃO DIAMÉTRICA DE ÁRVORES EM PARCELAS NO BIOMA AMAZÔNIA, PARA AS TIPOLOGIAS FLORESTA OMBRÓFILA DENSA – 164 PARCELAS - (A) E FLORESTA OMBRÓFILA ABERTA – 38 PARCELAS - (B), A PARTIR DOS DADOS DE INVENTÁRIO FLORESTAL DO PROJETO PAISAGENS SUSTENTÁVEIS, EMBRAPA. LINHA PONTILHADA NA VERTICAL REPRESENTA A MÉDIA ARITMÉTICA.



FONTE: A AUTORA (2021).

4.1.2 Estoques de biomassa e carbono e emissões de CO_{2eq}

Os estoques médios de biomassa nas localidades do Projeto Paisagens Sustentáveis da EMBRAPA, para parcelas de floresta densa, variaram de 100,76 (equação de Higuchi et al., 1998) a 328,35 Mg ha⁻¹ (equação de Silva, 2007) (TABELA 16). Os estoques médios de carbono e emissões de CO_{2eq} variaram de 62,01–157,61 Mg ha⁻¹ e 177,34–577,90 Mg ha⁻¹, respectivamente.

Em geral, os valores obtidos por meio da equação de Higuchi et al. (1998) foram inferiores aos valores obtidos por meio das equações de Chambers et al. (2001) e Silva (2007). Valores obtidos por meio da equação de Chambers et al. (2001), podem ser considerados intermediários, quando comparados aos valores de Higuchi et al. (1998) e Silva (2007). Isto é, em média, os valores de biomassa, carbono, e emissões de CO_{2eq} foram superiores aos obtidos por meio da equação de Higuchi et al. (1998),

e inferiores aos valores obtidos por meio da equação de Silva (2007). Portanto, os valores obtidos por meio da equação de Silva (2007) foram os mais altos, para todas as variáveis avaliadas, em comparação com as demais equações.

Para todas as equações de floresta densa avaliadas, maiores estoques médios de biomassa, carbono, e emissões de $\text{CO}_{2\text{eq}}$, foram encontrados para as localidades de Anambé (Pará) e FLONA do Tapajós (Pará) Área 1. Da mesma forma, menores valores de biomassa, carbono e emissões de $\text{CO}_{2\text{eq}}$ foram encontrados nas parcelas alocadas em Paragominas (Pará) e São Félix do Xingu (Pará) Área 1. Os estoques totais de biomassa acima do solo (BAS), para parcelas em floresta densa, foram iguais a 11.717,1; 11.696,4; e 14046,4 Mg, calculados a partir das equações de Higuchi et al. (1998), Chambers et al. (2001) e Silva (2007), respectivamente.

A similaridade nos valores obtidos a partir das equações de Higuchi et al. (1998) e Chambers et al. (2001) pode ser justificada pelo fato de que ambos estudos foram conduzidos em floresta densa de terra firme, na Amazônia central. A diferença entre as modelagens realizadas por esses autores se dá pelo fato de que Chambers et al. (2001) utilizaram um modelo cúbico (TABELA 12), com intensidade amostral de $n = 315$, e baixo valor de erro quadrático médio ($\text{MSE} = 0,297 \text{ Mg}$). Em contrapartida, Higuchi et al. (1998) testaram modelos lineares, três ao total, utilizando o DAP como variável dependente, sendo que a equação ajustada neste trabalho é indicada para valores de $\text{DAP} \geq 20 \text{ cm}$. Portanto, pode-se explicar diferenças nas estimativas entre as duas equações. Silva (2007) testou um modelo em potência ($n = 494$), o qual resultou em boas métricas estatísticas: $R^2 = 0,94$; $S_{yx} = 3,9\%$. Ressalta-se que o valor atipicamente baixo de RMSE encontrado por esta autora pode estar atrelado à baixa variabilidade das árvores utilizadas no estudo.

Os estoques de biomassa por unidade de área encontrados para as parcelas analisadas apresentaram alta variação (100,76 a 328,35 Mg ha^{-1}). Apesar de todas estarem classificadas como floresta densa, essas diferenças podem ser explicadas por possíveis heterogeneidades e particularidades das parcelas para cada localidade analisada. Por exemplo, nas parcelas localizadas em Paragominas, Pará, menores valores de biomassa por unidade de área. Em análise dos metadados dessa localidade, em particular, observa-se menor ocorrência densidade de indivíduos por parcela, quando comparada a outras parcelas analisadas em outras localidades. Já para localidades que apresentaram maiores valores de biomassa por hectare (por

exemplo, Fazenda Cauaxi e Tapajós, Área 1), a análise dos metadados das parcelas de inventário indica uma maior densidade de indivíduos por unidade de área.

Valores encontrados na literatura indicam que a biomassa por unidade de área na floresta amazônica, para tipologia floresta densa, variam de 267,56 a 273,79 Mg ha⁻¹ (MCTI, 2015; FAO, 2020). Na presente análise, as parcelas alocadas nos locais Anambé, Fazenda Cauaxi, Reserva Ducke, Santarém Área 1 e Tapajós Área 1 apresentaram valores semelhantes aos referenciados na literatura. Para as demais localidades, valores inferiores de biomassa por unidade de área foram encontrados, o que, tal como exposto acima, pode ser explicado pela menor densidade de indivíduos por unidade de área reportados nessas parcelas. Da mesma forma, análise semelhante pode ser realizada para valores estimados de carbono e emissões de CO_{2eq} nas parcelas de inventário florestal do Projeto Paisagens Sustentáveis aqui consideradas.

TABELA 16 – ESTOQUES DE BIOMASSA, CARBONO E EMISSÕES DE CO_{2eq} em Mg ha⁻¹, ESTIMADOS A PARTIR DAS EQUAÇÕES DE HIGUCHI ET AL. (1998), CHAMBERS ET AL. (2001) E SILVA (2007), PARA PARCELAS EM FLORESTA OMBRÓFILA DENSA. DADOS ORIUNDOS DO PROJETO PAISAGENS SUSTENTÁVEIS, EMBRAPA, NO BIOMA AMAZÔNIA.

Mg ha ⁻¹						
Local	Média de Biomassa			Média de Carbono		
	Higuchi et al. (1998)	Chambers et al. (2001)	Silva (2007)	Higuchi et al. (1998)	Chambers et al. (2001)	Silva (2007)
Anambé	272,46	272,82	328,35	130,78	130,95	157,61
Andiroba	156,56	155,25	201,69	75,15	74,52	96,81
Bonal	183,50	175,65	230,71	88,08	84,31	110,74
Fazenda Cauaxi	229,67	229,0	286,35	110,24	109,92	137,45
Ducke	226,37	233,55	269,49	108,66	112,10	129,36
Paragominas	100,76	102,64	133,94	48,36	49,27	64,29
Santarém, Área 1	205,62	202,97	264,87	98,70	97,43	127,14
Santarém, Área 2	163,30	166,94	217,49	78,38	80,13	104,40
São Félix do Xingu, Área 1	153,15	146,18	187,89	73,51	70,17	90,19
São Félix do Xingu, Área 3	129,18	133,07	167,37	62,01	63,87	80,34
Tapajós, Área 1	259,46	241,23	302,78	124,54	115,79	145,33
Tapajós, Área 3	138,05	103,39	159,28	66,26	49,63	76,45

TABELA 16 – Continuação.

Mg ha ⁻¹			
Local	Média de CO _{2eq}		
	Higuchi et al. (1998)	Chambers et al. (2001)	Silva (2007)
Anambé	479,53	480,16	577,90
Andiroba	275,55	273,24	354,97
Bonal	322,96	309,14	406,05
Fazenda Cauaxi	404,22	403,04	503,98
Ducke	398,41	411,05	474,30
Paragominas	177,34	180,65	235,73
Santarém, Área 1	361,89	357,23	466,17
Santarém, Área 2	287,41	293,81	382,78
São Félix do Xingu, Área 1	269,54	257,28	330,69
São Félix do Xingu, Área 3	227,36	234,20	294,57
Tapajós, Área 1	456,65	424,56	532,89
Tapajós, Área 3	242,97	181,97	280,33

Valores médios de biomassa estimados para parcelas de floresta aberta, nas localidades Humaitá (Acre) e FLONA do Jamari (Rondônia), variaram de 95,31 (equação 2 de Nogueira et al., 2008) a 252,90 Mg ha⁻¹ (equação 1 de Nogueira et al., 2008) (TABELA 17). Para valores obtidos por meio da Equação 1 de Nogueira et al. (2008), observaram-se maiores estoques para a localidade FLONA do Jamari, Área 3, sendo esses: 252,90 Mg ha⁻¹ de biomassa, 121,39 Mg ha⁻¹ de carbono e 445,10 Mg ha⁻¹ de emissões de CO_{2eq}. Já para valores obtidos a partir da Equação 2 de Nogueira et al. (2008), foram observados menores estoques de biomassa, carbono e emissões de CO_{2eq}.

Os estoques totais de biomassa acima do solo (BAS), para parcelas em floresta aberta, foram iguais a 1.282,48 e 754,41 Mg, calculados a partir das equações de Nogueira et al. (2008) Equação 1 e Nogueira et al. (2008) Equação 2, respectivamente.

TABELA 17 – ESTOQUES DE BIOMASSA E CARBONO, E EMISSÕES DE CO_{2EQ}, EM Mg ha⁻¹, ESTIMADOS A PARTIR DAS EQUAÇÕES DE NOGUEIRA ET AL. (2008) EQUAÇÃO 1 E NOGUEIRA ET AL. (2008) EQUAÇÃO 2, PARA PARCELAS EM FLORESTA OMBRÓFILA ABERTA. DADOS ORIUNDOS DO PROJETO PAISAGENS SUSTENTÁVEIS, EMBRAPA, NO BIOMA AMAZÔNIA.

Mg ha⁻¹						
Local	Média de Biomassa		Média de Carbono		Média de CO_{2eq}	
	Nogueira et al. (2008) Equação 1	Nogueira et al. (2008) Equação 2	Nogueira et al. (2008) Equação 1	Nogueira et al. (2008) Equação 2	Nogueira et al. (2008) Equação 1	Nogueira et al. (2008) Equação 2
Humaitá	158,04	95,31	75,86	45,75	278,15	167,75
Jamari, Área 1	188,27	113,67	90,37	54,56	331,36	200,06
Jamari, Área 3	252,90	153,22	121,39	73,55	445,10	269,67

Com relação aos valores de biomassa por unidade de área encontrados para as parcelas de floresta aberta, valores encontrados na literatura indicam que a biomassa por unidade de área na floresta amazônica, para tipologia floresta aberta, variam de 230,06 a 231,71 Mg ha⁻¹ (MCTI, 2015; FAO, 2020). Na presente análise, somente parcelas alocadas na FLONA do Jamari, Área 3, nas estimativas por meio da Equação 1 de Nogueira et al. (2008), apresentaram valores semelhantes aos referenciados na literatura. Para as demais localidades, valores inferiores de

biomassa por unidade de área foram encontrados, o que, pode ser explicado pela menor densidade de indivíduos por unidade de área reportados nessas parcelas. Por consequência, os valores de biomassa também refletem nos valores de carbono e emissões de CO_{2eq} estimados para estas parcelas em floresta aberta.

4.1.3 Comparações entre as estimativas obtidas por meio das equações de biomassa


Em análise das estimativas de biomassa por classes diamétricas obtidas por meio de 3 equações específicas de floresta densa (Higuchi et al., 1998; Chambers et al., 2001; Silva, 2007) e 2 equações genéricas para florestas tropicais (Brown, 1997 Equação 1 e Brown, 1997 Equação 2), observa-se maior concentração de estoques entre os diâmetros 50-60 cm (FIGURA 19).

Estoques de biomassa obtidos por meio da equação de Silva (2007) foram superiores aos valores obtidos por meio das demais equações, entre os diâmetros 5-75 cm, observando-se uma queda nos valores apenas para diâmetros superiores a 75 cm, ponto no qual as equações de Brown (1997) Equação 1, Higuchi et al. (1998) e Brown (1997) Equação 2 apresentam valores superiores de biomassa estimada. Ainda, entre as classes diamétricas IV-VIII (diâmetros entre 30-80 cm), as equações de Silva (2007) e Chambers et al. (2001) apresentaram maiores valores estimados de biomassa. Já para diâmetros superiores a 80 cm, destaque para a equação 2 de Brown (1997), que apresentou maiores concentrações de biomassa para indivíduos de grande porte.

Também se pode observar uma concentração nos valores de estoques de biomassa para indivíduos com diâmetro entre 40-50 cm, para todas as equações avaliadas. Dessa forma, constata-se que, apesar de um maior número de indivíduos concentrar-se nas classes diamétricas inferiores, tal qual observado na FIGURA 18.A, maiores estoques de biomassa concentram-se em árvores com DAPs entre 30-60 centímetros.

Os estoques totais de biomassa acima do solo (BAS), considerando todas as parcelas de floresta densa avaliadas, variaram de 11.696,41 (equação de Chambers et al., 2001) a 14.046,41 Mg (equação de Silva, 2007). Dessa forma, as classes diamétricas IV-VI (diâmetros entre 30-60 cm) concentraram os maiores estoques de biomassa.

FIGURA 19 – COMPARAÇÃO ENTRE OS RESULTADOS OBTIDOS POR CADA EQUAÇÃO ALOMÉTRICA TESTADA, NAS ESTIMATIVAS DOS ESTOQUES DE BIOMASSA EM FLORESTA DENSA. DADOS ORIUNDOS DO PROJETO PAISAGENS SUSTENTÁVEIS, EMBRAPA, NO BIOMA AMAZÔNIA.



FONTE: A AUTORA (2021).

A comparação dos valores médios de biomassa obtidos para floresta aberta denota os valores superiores obtidos por meio de Nogueira et al. (2008) Equação 1, quando comparada às estimativas obtidas por meio de Nogueira et al. (2008) Equação 2, para todas as classes diamétricas avaliadas (FIGURA 20). Nota-se ainda que, para dados de floresta aberta, as equações de Brown (1997) resultam em maiores valores de biomassa, para todas as classes diamétricas consideradas.

Indivíduos com diâmetros entre 40-80 cm concentraram os maiores estoques de biomassa, para todas as equações avaliadas, semelhante ao observado para árvores de floresta densa (FIGURA 19). Além disso, apesar de a maior frequência de indivíduos se concentrar nas classes diamétricas inferiores (FIGURA 18.B), maiores valores de biomassa concentram-se em árvores com diâmetros entre 40-80 cm.


Os estoques totais de biomassa acima do solo (BAS), considerando todas as parcelas de floresta aberta avaliadas, variaram de 754,01 (equação 1 de Nogueira et al., 2008) a 1.363,99 Mg (equação 2 de Brown, 1997). Dessa forma, as classes diamétricas IV-VI (diâmetros entre 40-70 cm) concentraram os maiores estoques de

biomassa.

Portanto, para dados de floresta aberta, é nítida a diferença entre as estimativas calculadas por meio de equações específicas e estimativas por meio das equações genéricas. A partir do cálculo das diferenças percentuais entre os valores obtidos por meio das equações genéricas e equações específicas, observa-se que a Equação 1 de Brown (1997) superestimou valores de biomassa, com relação à Nogueira et al. (2008) Equação 1, em 4,67% (classe diamétrica VI) a 13,86% (classe III). Com relação à Nogueira et al. (2008) Equação 2, superestimativas variaram de 36,20% (classe X) a 47,44% (classe III). Apenas nas classes diamétricas VIII, IX e X os valores de biomassa estimados por Nogueira et al. (2008) Equação 1 superaram os valores obtidos por meio de Brown (1997) Equação 1, em 1,73%, 5,43% e 14,87%, respectivamente (FIGURA 20).

Já a Equação 2 de Brown (1997) superestimou os valores de biomassa, com relação à Nogueira et al. (2008) Equação 1, de 0,36% (classe diamétrica III) a 13,48% (classe X). Somente para as classes I e II os valores de biomassa estimados por Nogueira et al. (2008) Equação 1 superaram os valores obtidos por meio de Brown (1997) Equação 2, em 10,29% e 4,39%, respectivamente. Com relação à Nogueira et al. (2008) Equação 2, superestimativas variaram de 27,98% (classe I) a 51,94% (classe X).

FIGURA 20 – COMPARAÇÃO ENTRE OS RESULTADOS OBTIDOS POR CADA EQUAÇÃO ALOMÉTRICA TESTADA, NAS ESTIMATIVAS DOS ESTOQUES DE BIOMASSA EM FLORESTA ABERTA. DADOS ORIUNDOS DO PROJETO PAISAGENS SUSTENTÁVEIS, EMBRAPA, NO BIOMA AMAZÔNIA.



FONTE: A AUTORA (2021).

Os intervalos de confiança de 95%, calculados para dados de floresta densa e floresta aberta (APÊNDICES 2 e 3) indicaram que, para as ambas as tipologias avaliadas, os estoques de biomassa concentraram-se nas classes diamétricas IV-VI (diâmetros entre 40-70 cm). Portanto, há uma diferença no comportamento da distribuição da biomassa, conforme a utilização de diferentes equações alométricas para estimá-la, corroborando com os resultados observados nas TABELAS 16 e 17 e nas FIGURAS 19 e 20.

4.2 ESTIMATIVAS DE BIOMASSA E CARBONO PARA DADOS DO PROJETO RADAMBRASIL

4.2.1 Distribuição diamétrica

A descrição da base de dados do Projeto RADAMBRASIL, utilizada para calcular os estoques de biomassa por meio de equações de biomassa, ($n = 114.231$ árvores), está apresentada na TABELA 18:

TABELA 18 – DESCRIÇÃO DA BASE DE DADOS DO PROJETO PAISAGENS SUSTENTÁVEIS DA EMBRAPA, PARA A VARIÁVEL DIÂMETRO À ALTURA DO PEITO.

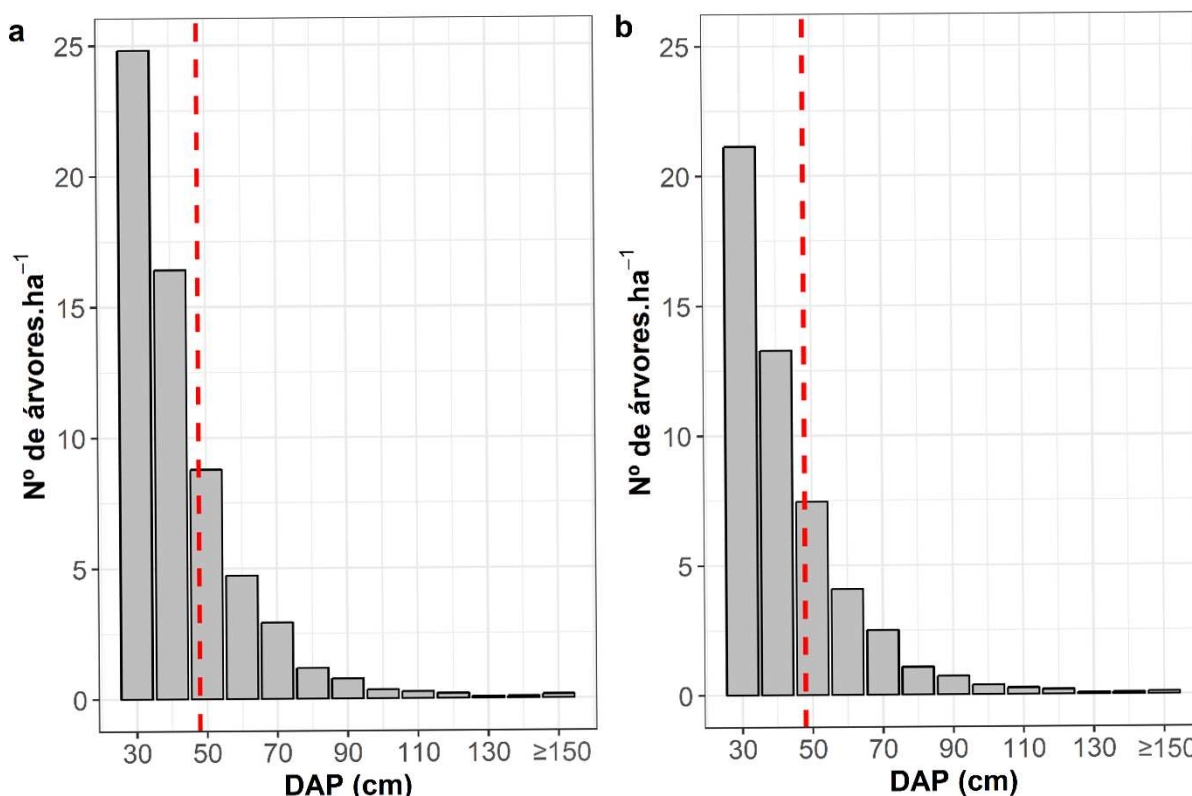
Variável	Valor mínimo	Valor máximo	Média	Desvio padrão
Diâmetro à altura do peito (cm)	30,0	306,0	48,07	17,94

FONTE: A AUTORA (2021)

A distribuição diamétrica dos indivíduos arbóreos para floresta densa segue o padrão decrescente, em forma de “J invertido”, característico de florestas tropicais (FIGURA 21). O maior número de indivíduos está na classe 30-40 cm (28.737), seguida pelas classes 40-50 cm (19.010) e 50-60 cm (10.172). Essas três classes diamétricas contemplam 84% dos indivíduos de floresta densa (FIGURA 21.A).

Para dados de floresta aberta, o mesmo padrão de distribuição “J invertido” pode ser observado (FIGURA 21.B). Nota-se, no entanto, um menor número total de indivíduos arbóreos, em comparação com dados de floresta densa, o que reflete a composição dessa tipologia, uma vez que a floresta aberta é caracterizada por uma menor densidade de indivíduos por unidade de área. O maior número de indivíduos encontra-se, tal qual na floresta densa, nas classes 30-40 cm (18.054 indivíduos), 40-50 cm (11.132) e 50-60 cm (6.371). Essas classes contemplam 82% dos indivíduos arbóreos para a tipologia floresta aberta.

FIGURA 21 – DISTRIBUIÇÃO DIAMÉTRICA DE ÁRVORES EM PARCELAS NO BIOMA AMAZÔNIA, PARA AS TIPOLOGIAS FLORESTA OMBRÓFILA DENSA – 1.158 PARCELAS - (A) E FLORESTA OMBRÓFILA ABERTA – 854 PARCELAS - (B), A PARTIR DOS DADOS DE INVENTÁRIO FLORESTAL DO PROJETO RADAMBRASIL. LINHA PONTILHADA NA VERTICAL REPRESENTA A MÉDIA ARITMÉTICA.



FONTE: A AUTORA (2021).

A análise de distribuição diamétrica – para árvores com DAP ≥ 30 cm - denota a importância das tipologias floresta densa e floresta aberta na composição arbórea do bioma Amazônia, assim como sua relevante importância na diversidade de espécies, conservação e biodiversidade desse bioma (HOPKINS, 2007; RIBEIRO, 1999). Além disso, resultados obtidos a partir dessa distribuição possibilitam a realização de outras análises, tais como estimativas de biomassa, carbono e emissões de CO_{2eq} para as tipologias florestais aqui estudadas. Somente na abordagem conduzida no presente trabalho (que não compõe a totalidade de dados disponibilizados pelo BDIA para o bioma Amazônia), cerca de 114.000 indivíduos arbóreos foram analisados, denotando o grande esforço amostral nas atividades de inventário florestal conduzidos pelo Projeto RADAMBRASIL.

Entretanto, desde a execução do Projeto RADAM – desde meados das décadas de 1970 e 1980 -, poucas iniciativas de inventário florestal, de grande

abrangência territorial, foram conduzidas no bioma Amazônia, devido à complexidade logística e vasta extensão dos estados que compõem esse bioma. Nesse ponto, vale destacar a iniciativa do Serviço Florestal Brasileiro na implementação do Inventário Florestal Nacional (IFN), a partir de 2007, com atividades conduzidas em cada estado da federação (CTN-IFN/BR, 2020).

Contudo, as atividades do IFN nos estados que compõe o bioma Amazônia ainda não têm data prevista para serem concluídas. Porém, assim que os resultados forem publicados e disponibilizados, análises, tais quais as conduzidas no presente trabalho, podem ser realizadas para fins de comparação dos resultados do IFN com os resultados do Projeto RADAMBRASIL.

4.2.2 Estoques de biomassa e carbono e emissões de CO_{2eq}

Verificou-se que as classes diamétricas inferiores ($DAP \leq 80$ cm) concentraram maiores valores estocados de biomassa e carbono, além de emissões de CO_{2eq}, para floresta ombrófila densa, sendo isto constatado para todas as equações testada (TABELA 19). As equações de Higuchi et al. (1998) e Chambers et al. (2001) estimaram valores semelhantes de biomassa, carbono e emissões de CO_{2eq}, enquanto a equação de Silva (2007) demonstrou maiores valores dessas variáveis. Os estoques de biomassa estimados, para as 1.158 parcelas analisadas, foram 180.981, 181.531 e 203.649 Mg, a partir das equações de Higuchi et al. (1998), Chambers et al. (2001) e Silva (2007), respectivamente. Também se constatou que 75,9% da biomassa concentra-se nas classes I-V (30-80 cm) a partir da equação de Higuchi et al. (1998), 83,5% a partir da equação de Chambers et al. (2001), e 79,5% a partir da equação de Silva (2007). Ou seja, mais de 75% da biomassa está estocada em árvores com $DAP \leq 80$ cm.

O resultado acima difere do encontrado por Slik et al. (2013). Esses autores encontraram que as árvores com $DAP \geq 70$ cm estocam cerca de 70% da biomassa em ambientes pantropicais (SLIK et al., 2013). Entretanto, nesse estudo, os autores analisaram dados de apenas 120 parcelas, distribuídas na região pantropical e alocadas em florestas primárias (não perturbadas). No presente trabalho, foram analisados dados oriundos da maior base de levantamentos florestais para o bioma Amazônia no Brasil, com a inclusão de 2.012 parcelas, alocadas em duas tipologias florestais, floresta densa e floresta aberta. Portanto, diferenças nas regiões

abrangidas pelos estudos e número de parcelas consideradas justificam as diferenças encontradas.

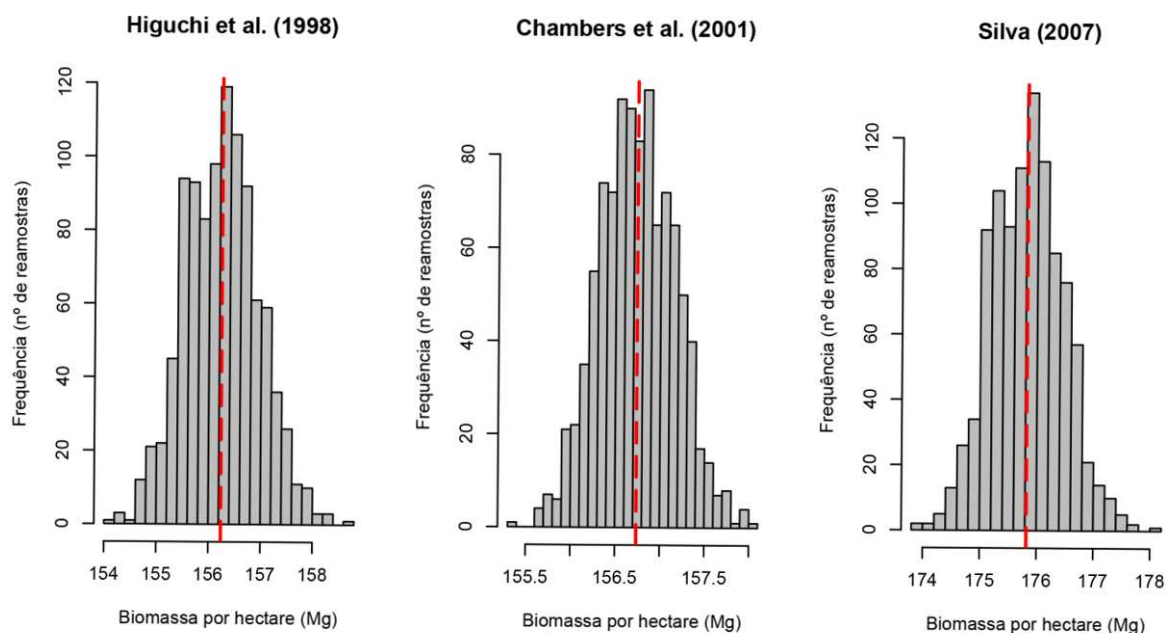
As classes II (40-50 cm) e XI (130-140 cm) concentraram os maiores e menores estoques de biomassa e carbono, respectivamente, para todas as equações de floresta densa analisadas. Tal qual para as estimativas de biomassa, as classes I-V concentraram os maiores estoques de carbono. Os estoques totais de carbono foram 86.854 – Higuchi et al. (1998), 87.123 – Chambers et al. (2001), e 97.735 Mg – Silva (2007) (APÊNDICE 4). Observou-se, também, que a classe XIII (DAP \geq 150 cm), embora apresente menor número de indivíduos por unidade de área, concentrou maiores estoques de biomassa e carbono do que as classes VIII-XII (100-150 cm), para as equações de Higuchi et al. (1998) e Silva (2007).

As emissões de CO_{2eq} foram iguais a 318.526, 319.494, e 358.422 Mg, para as equações de Higuchi et al. (1998), Chambers et al. (2001) e Silva (2007), respectivamente (APÊNDICE 4). Esses valores correspondem aos valores totais de gases de efeito estufa (GEEs) que deixaram de ser emitidos (floresta em pé), durante o período em que os levantamentos florestais foram realizados, para todas as parcelas de floresta densa avaliadas nesse estudo, ou seja, 1.158 hectares.

A média de biomassa estocada por unidade de área variou de 156,3 Mg ha⁻¹ (equação de Higuchi et al., 1998) a 175,9 Mg ha⁻¹ (equação de Silva, 2007) (TABELA 19 e FIGURA 22). Os estoques de carbono e emissões de CO_{2eq} variaram de 75,1-84,4 Mg ha⁻¹ a 275,1-309,6 Mg ha⁻¹, respectivamente. Mello et al. (2016), ao estimarem a biomassa de mais de 16.000 árvores no estado do Pará, por meio de equações de biomassa, encontraram variações de 196 Mg ha⁻¹ (equação de Brown et al., 1989) a 255 Mg ha⁻¹ (equação de Higuchi et al., 1998).

Esses valores, no entanto, encontram-se abaixo da média de biomassa por hectare estimada a floresta amazônica (SAATCHI et al., 2011; BACCINI et al., 2012; FAO, 2020). Valores mais baixos de biomassa por hectare encontrados podem ser explicados devido ao fato que, no presente trabalho, considerou-se apenas a inclusão de indivíduos arbóreos, com diâmetro \geq 30 cm. Além disso, não foram utilizados fatores de expansão de biomassa, para incluir árvores com diâmetro $<$ 30 cm e para incluir demais compartimentos acima do solo (ex. palmeiras, cipós, serapilheira e sub-bosque).

FIGURA 22 – DISTRIBUIÇÃO DA BIOMASSA POR HECTARE PELO NÚMERO DE REAMOSTRAS BOOTSTRAP, PARA CADA EQUAÇÃO ALOMÉTRICA DE FLORESTA DENSA TESTADA. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA. LINHA PONTILHADA NA VERTICAL REPRESENTA A MÉDIA DAS REAMOSTRAGENS BOOTSTRAPP PARA CADA EQUAÇÃO.



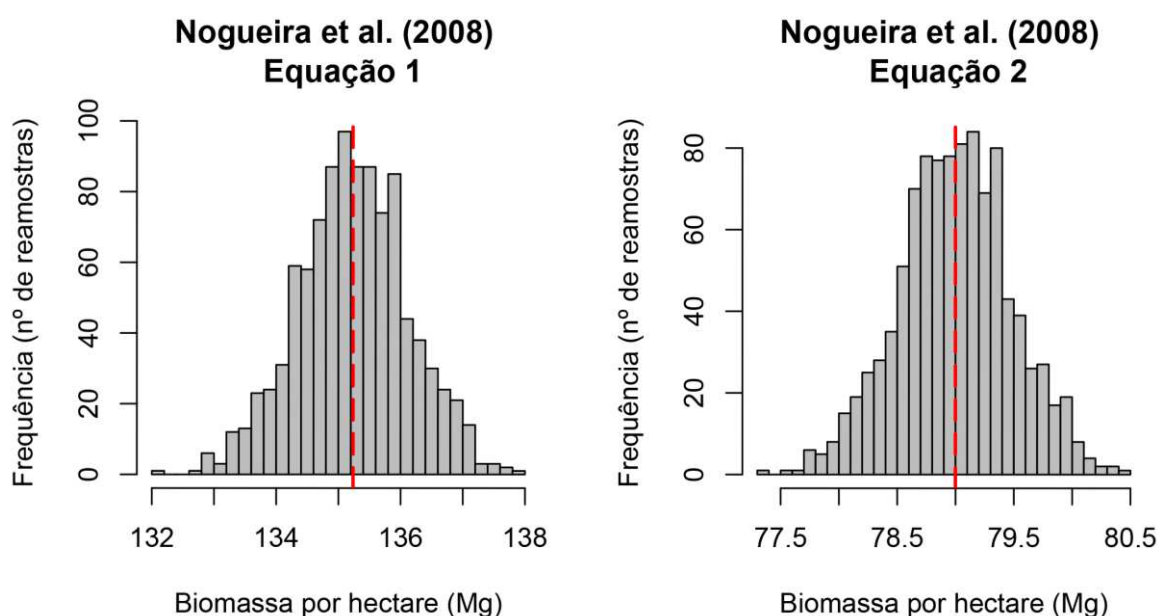
FONTE: A AUTORA (2021).

Em estudos cujas estimativas de biomassa foram obtidas pelo método indireto (equações de biomassa) na Amazônia brasileira, para floresta densa, os valores de biomassa viva acima do solo variaram consideravelmente, de 142,3 Mg ha⁻¹ (FEARNSIDE; LEAL; FERNANDES, 1993) a 268 Mg ha⁻¹ (BROWN; LUGO, 1992). Higuchi et al. (1998) argumentam que discrepâncias nas estimativas de biomassa ao longo do tempo, no ajuste de novas equações, ocorrem mesmo que estas sejam desenvolvidas pelos mesmos autores e utilizando a mesma base de dados, o que pode ser justificado pelo uso de diferentes métodos (diretos e indiretos) e pelo uso de diferentes variáveis de entrada nos modelos (DAP; DAP e altura; DAP, altura e densidade).

Para dados de floresta aberta, as estimativas de biomassa e carbono, e emissões de CO_{2eq}, obtidas a partir da equação de Nogueira et al. (2008) Equação 2 foram inferiores aos valores obtidos a partir da equação Nogueira et al. (2008) Equação 1, para valores totais e por hectare. Os valores totais de biomassa, carbono

e emissões de $\text{CO}_{2\text{eq}}$ a partir de Nogueira et al. (2008) Equação 1 foram: 115.512, 55.446, e 203.302 Mg, respectivamente (APÊNDICE 5). Quando aplicada a Equação 2 de Nogueira et al. (2008), os valores totais encontrados foram: 67.476 Mg de biomassa, 32.388 Mg carbono e 118.758 Mg de emissões de $\text{CO}_{2\text{eq}}$. Portanto, os valores obtidos pela Equação 2 corresponderam à, aproximadamente, metade dos valores obtidos pela Equação 1. A média de biomassa estocada por unidade de área (hectare) variou de 79,09 Mg ha^{-1} (Nogueira et al., 2008 Equação 2) a 135,3 Mg ha^{-1} (Nogueira et al., 2008 Equação 1) (TABELA 20 e FIGURA 23). Já os estoques de carbono variaram de 37,93 (Nogueira et al., 2008 Equação 2) a 64,93 Mg ha^{-1} (Nogueira et al., 2008 Equação 1).

FIGURA 23 – DISTRIBUIÇÃO DA BIOMASSA POR HECTARE PELO NÚMERO DE REAMOSTRAS BOOTSTRAP, PARA CADA EQUAÇÃO ALOMÉTRICA DE FLORESTA ABERTA TESTADA. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA. LINHA PONTILHADA NA VERTICAL REPRESENTA A MÉDIA DAS REAMOSTRAGENS BOOTSTRAPP PARA CADA EQUAÇÃO.



FONTE: A AUTORA (2021).

A variação nos valores estimados por meio das duas equações de floresta aberta pode ser justificada pelo fato de que a Equação 1 foi ajustada para a obtenção do peso seco de biomassa da “árvore inteira” (fuste, copa e galhos). Com relação à Equação 2, esta foi ajustada, para o mesmo conjunto de dados ($n = 262$), para a obtenção apenas do peso seco do fuste, resultando, portanto, em menores valores de

biomassa e carbono. Esses resultados denotam que, mesmo para um mesmo conjunto de dados, as estimativas de biomassa e carbono podem variar consideravelmente, de acordo com os diferentes compartimentos das árvores para os quais deseja-se obter estimativas.

TABELA 19 – ESTOQUES DE BIOMASSA E CARBONO, E EMISSÕES DE CO_{2eq} (Mg ha⁻¹), ESTIMADOS A PARTIR DAS EQUAÇÕES DE HIGUCHI ET AL. (1998), CHAMBERS ET AL. (2001) E SILVA (2007), PARA 1.158 PARCELAS EM FLORESTA OMBRÓFILA DENSE. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA.

Mg ha ⁻¹						
Classes diamétricas	Biomassa			Carbono		
	Higuchi et al. (1998)	Chambers et al. (2001)	Silva (2007)	Higuchi et al. (1998)	Chambers et al. (2001)	Silva (2007)
I	27,80	31,44	35,69	13,34	15,09	17,13
II	30,39	34,93	36,80	14,59	16,76	17,66
III	24,88	27,91	28,66	11,94	13,40	13,76
IV	19,02	20,31	21,04	9,13	9,75	10,10
V	16,55	16,34	17,59	7,95	7,84	8,44
VI	9,11	8,16	9,34	4,37	3,92	4,48
VII	7,44	6,11	7,44	3,57	2,93	3,57
VIII	4,15	3,11	4,05	1,99	1,49	1,94
IX	3,77	2,56	3,60	1,81	1,23	1,73
X	3,44	2,07	3,21	1,65	0,99	1,54
XI	1,59	0,87	1,46	0,76	0,42	0,70
XII	2,06	1,01	1,86	0,99	0,48	0,89
XIII	6,08	1,96	5,14	2,92	0,94	2,47
Total	156,29	156,76	175,86	75,02	75,25	84,41

TABELA 19 – CONTINUAÇÃO.

Mg ha ⁻¹			
Classes diamétricas	CO _{2eq}		
	Higuchi et al. (1998)	Chambers et al. (2001)	Silva (2007)
I	48,93	55,34	62,81
II	53,49	61,47	64,77
III	43,78	49,12	50,45
IV	33,47	35,74	37,02
V	29,13	28,75	30,96
VI	16,03	14,36	16,43
VII	13,10	10,75	13,09
VIII	7,31	5,48	7,13
IX	6,63	4,50	6,33
X	6,06	3,65	5,65
XI	2,80	1,53	2,57
XII	3,63	1,77	3,27
XIII	10,70	3,44	9,05
Total	275,07	275,90	309,52

TABELA 20 – ESTOQUES DE BIOMASSA E CARBONO, E EMISSÕES DE CO_{2eq} (Mg ha⁻¹), ESTIMADOS A PARTIR DAS EQUAÇÕES DE NOGUEIRA ET AL. (2008) EQUAÇÃO 1 E NOGUEIRA ET AL. (2008) EQUAÇÃO 2, PARA 854 PARCELAS EM FLORESTA OMBRÓFILA ABERTA. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA.

Mg ha ⁻¹						
Classes diamétricas	Biomassa		Carbono		CO _{2eq}	
	Nogueira et al. (2008) Equação 1	Nogueira et al. (2008) Equação 2	Nogueira et al. (2008) Equação 1	Nogueira et al. (2008) Equação 2	Nogueira et al. (2008) Equação 1	Nogueira et al. (2008) Equação 2
I	20,61	12,61	9,89	6,05	36,28	22,19
II	22,78	13,69	10,94	6,57	40,10	24,09
III	20,40	12,07	9,79	5,79	35,90	21,24
IV	16,58	9,69	7,96	4,65	29,19	17,06
V	14,65	8,46	7,03	4,06	25,79	14,89
VI	8,95	5,11	4,30	2,45	15,76	9,00
VII	7,75	4,39	3,72	2,11	13,63	7,72
VIII	5,03	2,83	2,41	1,36	8,85	4,98
IX	4,25	2,38	2,04	1,14	7,49	4,18
X	4,24	2,35	2,04	1,13	7,47	4,14
XI	1,77	0,98	0,85	0,47	3,11	1,72
XII	2,45	1,34	1,18	0,64	4,31	2,36
XIII	5,79	3,12	2,78	1,50	10,18	5,48
Total	135,26	79,01	64,93	37,93	238,06	139,06

4.2.3 Comparações entre as estimativas obtidas por meio das equações de biomassa

Comparando os valores médios de biomassa obtidos por meio de cada equação, para todas as classes diamétricas, observa-se que, na floresta densa, as estimativas obtidas a partir da equação de Silva (2007) resultaram em maiores valores de biomassa, quando comparada às demais equações, para todas as classes diamétricas analisadas (FIGURA 24). Em contraste, a equação de Higuchi et al. (1998) resultou em menores valores de biomassa, para diâmetros entre 30 e 75 cm (classes I-V). Ademais, para as classes VI-XII (80-150 cm) de DAP, os valores obtidos por esta equação convergem para valores semelhantes de biomassa obtidos pela equação de Silva (2007), com estimativas superiores às obtidas pela equação de Chambers et al. (2001). Também podem ser observados valores intermediários de biomassa entre as classes 30-75 cm a partir da equação e Chambers et al. (2001), enquanto para árvores com diâmetros superiores a 75 cm, menores valores de biomassa foram detectados. Para todas as equações, a classe II (40-50 cm) concentrou os maiores estoques de biomassa total: Silva et al. (2007): 42.613,71 Mg; Chambers et al. (2001): 40.443,24 Mg; e Higuchi et al. (1998): 35.191,74 Mg (APÊNDICE 4).


As estimativas obtidas pelas equações de Brown (1997), em comparação com as equações específicas para floresta densa, foram menores, quando comparadas às estimativas obtidas pelas equações de Silva (2007) e Chambers et al. (2001), para as classes diamétricas de I-V. Porém, observa-se que, para indivíduos acima de 75 cm de diâmetro, as duas equações de Brown (1997), com destaque para a Equação 2, estimaram maiores valores de biomassa que as demais equações consideradas.

Observa-se que, em média, os valores de biomassa obtidos por meio das equações de Brown (1997), Equação 1 e Equação 2, foram: 163,28 Mg ha⁻¹ e 168,48 Mg ha⁻¹. Esses valores foram próximos aos encontrados por meio da equação de Silva (2007). Entretanto, as médias de biomassa para estas equações genéricas de ambientes tropicais foram 2,9% (Brown, 1997 Equação 1) e 6,2% (Brown, 1997 Equação 2), maiores que a média encontrada para equações específicas de floresta densa (158,14 Mg ha⁻¹).

Em comparação com dados publicados pelo Terceiro Inventário Brasileiro de Emissões e Remoções Antrópicas de Gases de Efeito Estufa (MCTI, 2015), o valor médio encontrado pelas equações de floresta densa corresponde a 57,76% do valor

médio de 273,79 Mg ha^{-1} , publicado no relatório. Já os valores encontrados pelas equações de Brown (1997) Equação 1 e Brown (1997) Equação 2 correspondem a 59,42% e 61,32%, respectivamente, do valor reportado no relatório do MCTI (2015).

FIGURA 24 – COMPARAÇÃO ENTRE OS RESULTADOS OBTIDOS POR CADA EQUAÇÃO ALOMÉTRICA TESTADA, NAS ESTIMATIVAS DOS ESTOQUES DE BIOMASSA EM FLORESTA DENSA. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA.



FONTE: A AUTORA (2021).


A comparação dos valores médios de biomassa obtidos para floresta aberta denota os valores superiores obtidos por meio de Nogueira et al. (2008) Equação 1, para todas as classes diamétricas avaliadas (FIGURA 25). Além disso, observa-se que os estoques de biomassa, para as duas equações avaliadas, estão concentrados nas classes I-V (até 80 cm de diâmetro), tal qual observado para dados de floresta densa (FIGURA 24). Nota-se que, para dados de floresta aberta, as equações de Brown (1997) resultam em maiores valores de biomassa, para todas as classes diamétricas consideradas.

Os valores de biomassa obtidos por meio de Brown (1997) Equação 1 e Brown (1997) Equação 2, de 140,23 Mg ha^{-1} e 145,24 Mg ha^{-1} , foram, respectivamente, 30,86% e 35,52%, maiores que a média encontrada por meio das equações específicas de floresta aberta (107,14 Mg ha^{-1}). Em comparação com valores

publicados pelo Terceiro Inventário Brasileiro de Emissões e Remoções Antrópicas de Gases de Efeito Estufa, o valor médio encontrado pelas equações de aberta corresponde a 46,24% do valor médio para florestas densas publicado no relatório, de 231,71 Mg ha⁻¹ (MCTI, 2015). Já os valores encontrados por meio de Brown (1997) Equação 1 e Brown (1997) Equação 2 correspondem a 60,51% e 62,66%, respectivamente, do valor reportado no relatório do MCTI (2015).

Portanto, para dados de floresta aberta, é nítida a diferença encontrada nas estimativas feitas por meio de equações específicas para esta tipologia, daquela encontrada por meio das equações genéricas, de Brown (1997), superestimando os valores no percentual de 24,9%. Dessa forma, denota-se a inadequabilidade do uso de equações genéricas, tal como de Brown (1997), nas estimativas de biomassa para tipologias florestais específicas.

FIGURA 25 – COMPARAÇÃO ENTRE OS RESULTADOS OBTIDOS POR CADA EQUAÇÃO ALOMÉTRICA TESTADA, NAS ESTIMATIVAS DOS ESTOQUES DE BIOMASSA EM FLORESTA ABERTA. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA.



FONTE: A AUTORA (2021).

Nogueira et al. (2008) também compararam estimativas de biomassa em seu conjunto de dados (florestas abertas no sul da Amazônia), utilizando as mesmas equações aplicadas nesse artigo - Higuchi et al., (1998), Chambers et al. (2001) e

Silva (2007). Foi constatado que a equação de Silva (2007) apresentou maiores divergências, em porcentagem, de biomassa estimada, além de superestimativa dos valores de biomassa a partir da equação de Chambers et al. (2001), corroborando com os resultados obtidos no presente trabalho de tese.

Os intervalos de confiança calculados para dados de Floresta Densa e Floresta Aberta (APÊNDICES 6 e 7) indicaram que, para ambas as tipologias avaliadas, os estoques de biomassa, carbono e emissões de CO_{2eq} concentraram-se nas classes diamétricas I-V, confirmando os resultados observados nas TABELAS 19 e 20 e nas FIGURAS 24 e 25. Portanto, há uma diferença no comportamento da distribuição da biomassa, conforme a utilização de diferentes equações alométricas para estimá-la,

4.2.4 Mapas de biomassa e carbono

Foram gerados 32 mapas de distribuição da biomassa e carbono de árvores para a extensão do bioma Amazônia (FIGURAS 26-29). Aqui, propõe-se uma nova abordagem de espacialização da biomassa viva de árvores no bioma Amazônia, a partir da interpolação de valores estimados por meio de equações de biomassa, em metodologia inédita para dados de florestas inventariadas pelo Projeto RADAMBRASIL.

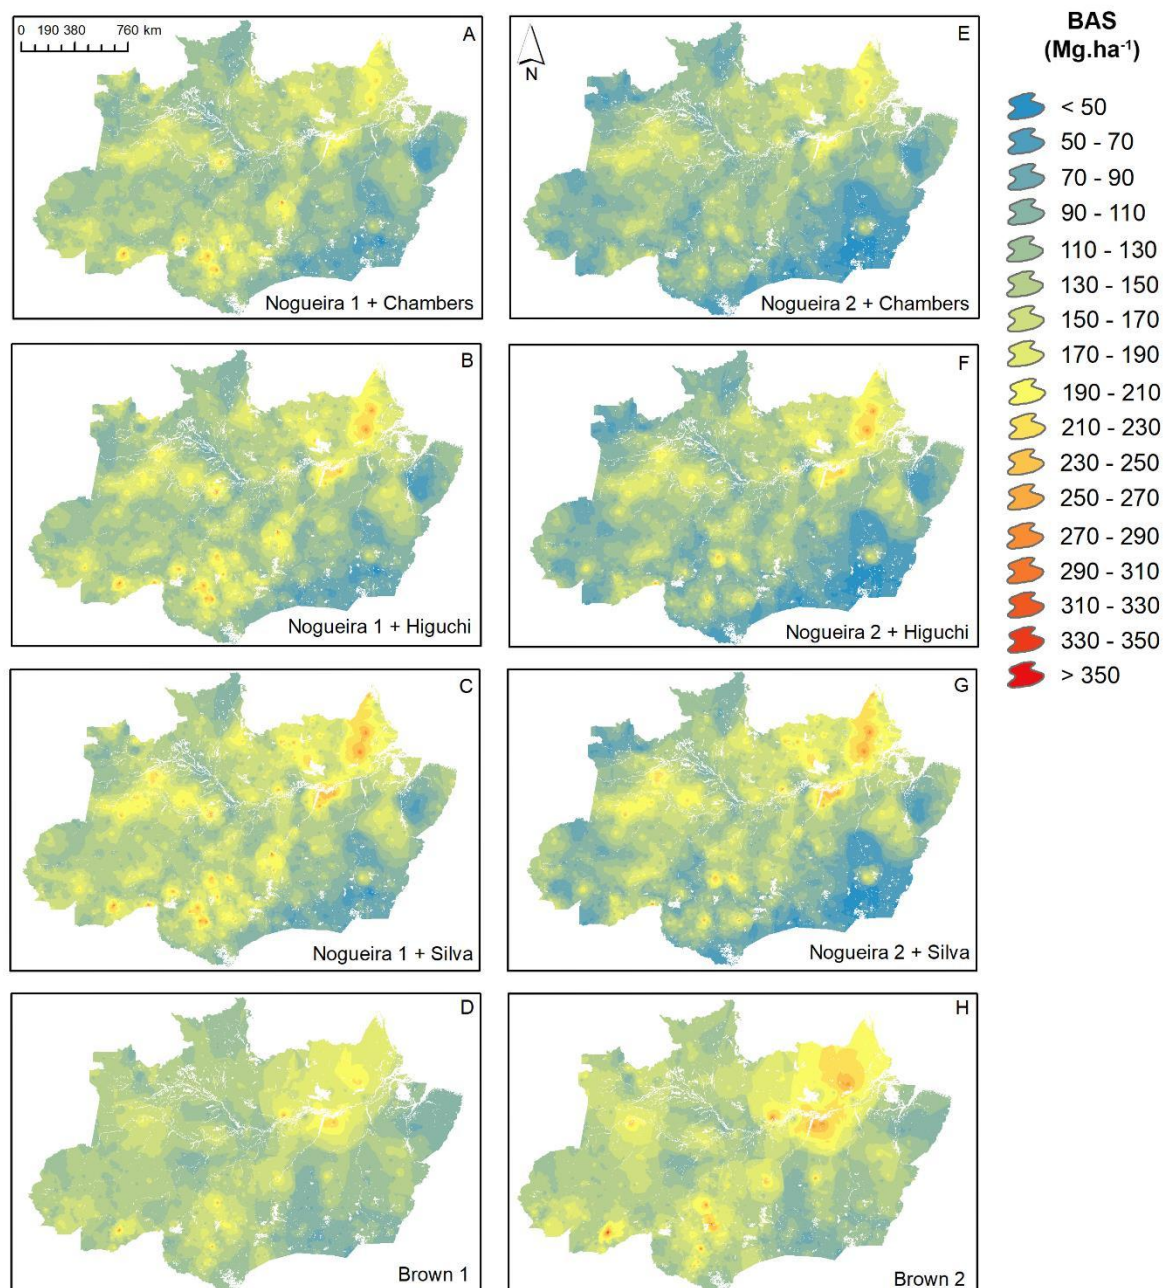
Os mapas gerados combinam resultados de equações de biomassa para floresta densa e floresta aberta, além dos resultados obtidos por meio de Brown (1997) Equação 1 e Brown (1997) Equação 2, genéricas para florestas tropicais, considerando quatro cenários: 1. Distribuição de biomassa por hectare, considerando árvores com DAP ≥ 30 cm (FIGURA 26.A-H); 2. Distribuição de biomassa por hectare, utilizando um fator de expansão para incluir árvores com $10 \leq \text{DAP} < 30$ cm, além de árvores com DAP ≥ 30 cm (FIGURA 27.A-H); 3. Distribuição de carbono por hectare, considerando árvores com DAP ≥ 30 cm (FIGURA 28.A-H); e 4. Distribuição de carbono por hectare, utilizando um fator de expansão para incluir árvores com $10 \leq \text{DAP} < 30$ cm, além de árvores com DAP ≥ 30 cm (FIGURA 29.A-H).

Observa-se que a distribuição da biomassa, considerando estimativas obtidas pela equação de Silva (2007) em combinação com dados de floresta aberta, apresentou os maiores valores de biomassa por hectare, com concentração principalmente na região sul (Amazonas e Rondônia) e na região nordeste da floresta amazônica (Pará e Amapá) (FIGURAS 26.C e 26.G). Em contrapartida, resultados

obtidos a partir da equação de Chambers et al. (2001), em combinação com dados de floresta aberta (FIGURAS 26.A e 26.E), indicaram menores valores de biomassa estimados, em concordância com os resultados já abordados no presente trabalho (FIGURAS 24-25). A distribuição da biomassa a partir das equações de Higuchi et al. (1998) e Nogueira et al. (2008) (FIGURAS 26.B e 26.F) assemelha-se à distribuição das FIGURAS 26.C e 26.G (Silva, 2007 + Nogueira et al. 2008), com maiores concentrações na porção ocidental da floresta amazônica (Pará e Amapá), no sul da Amazônia (Amazonas, Roraima) e na Amazônia central (Amazonas).

Os mapas gerados a partir das equações de Brown (1997) indicaram maiores valores de biomassa por unidade de área, denotada nas regiões nordeste e sul do bioma Amazônia. Dessa forma, a utilização de equações genéricas para florestas tropicais resultou em superestimativas de biomassa aérea de árvores, quando comparada às estimativas obtidas por meio de equações específicas para tipologias florestais. Essas equações também apresentaram maiores valores de biomassa por unidade de área: 162,7 Mg ha⁻¹ e 167,9 Mg ha⁻¹, para Brown (1997) Equação 1 e Brown (1997) Equação 2, respectivamente.

FIGURA 26 – MAPAS DE BIOMASSA FLORESTAL ACIMA DO SOLO (BAS), PARA FLORESTA DENSE E FLORESTA ABERTA NO BIOMA AMAZÔNICO BRASILEIRO, A PARTIR DE DADOS DE INVENTÁRIO FLORESTAL DO PROJETO RADAMBRASIL, PARA ÁRVORES COM DAP ≥ 30 cm: A. Chambers et al. (2001) e Nogueira et al. (2008) Equação 1; B. Higuchi et al. (1998) e Nogueira et al. (2008) Equação 1; C. Silva (2007) e Nogueira et al. (2008) Equação 1; D. Brown (1997) Equação 1; E. Chambers et al. (2001) e Nogueira et al. (2008) Equação 2; F. Higuchi et al. (1998) e Nogueira et al. (2008) Equação 2; G. Silva (2007) e Nogueira et al. (2008) Equação 2; H. Brown (1997) Equação 2.



FONTE: A AUTORA (2021).

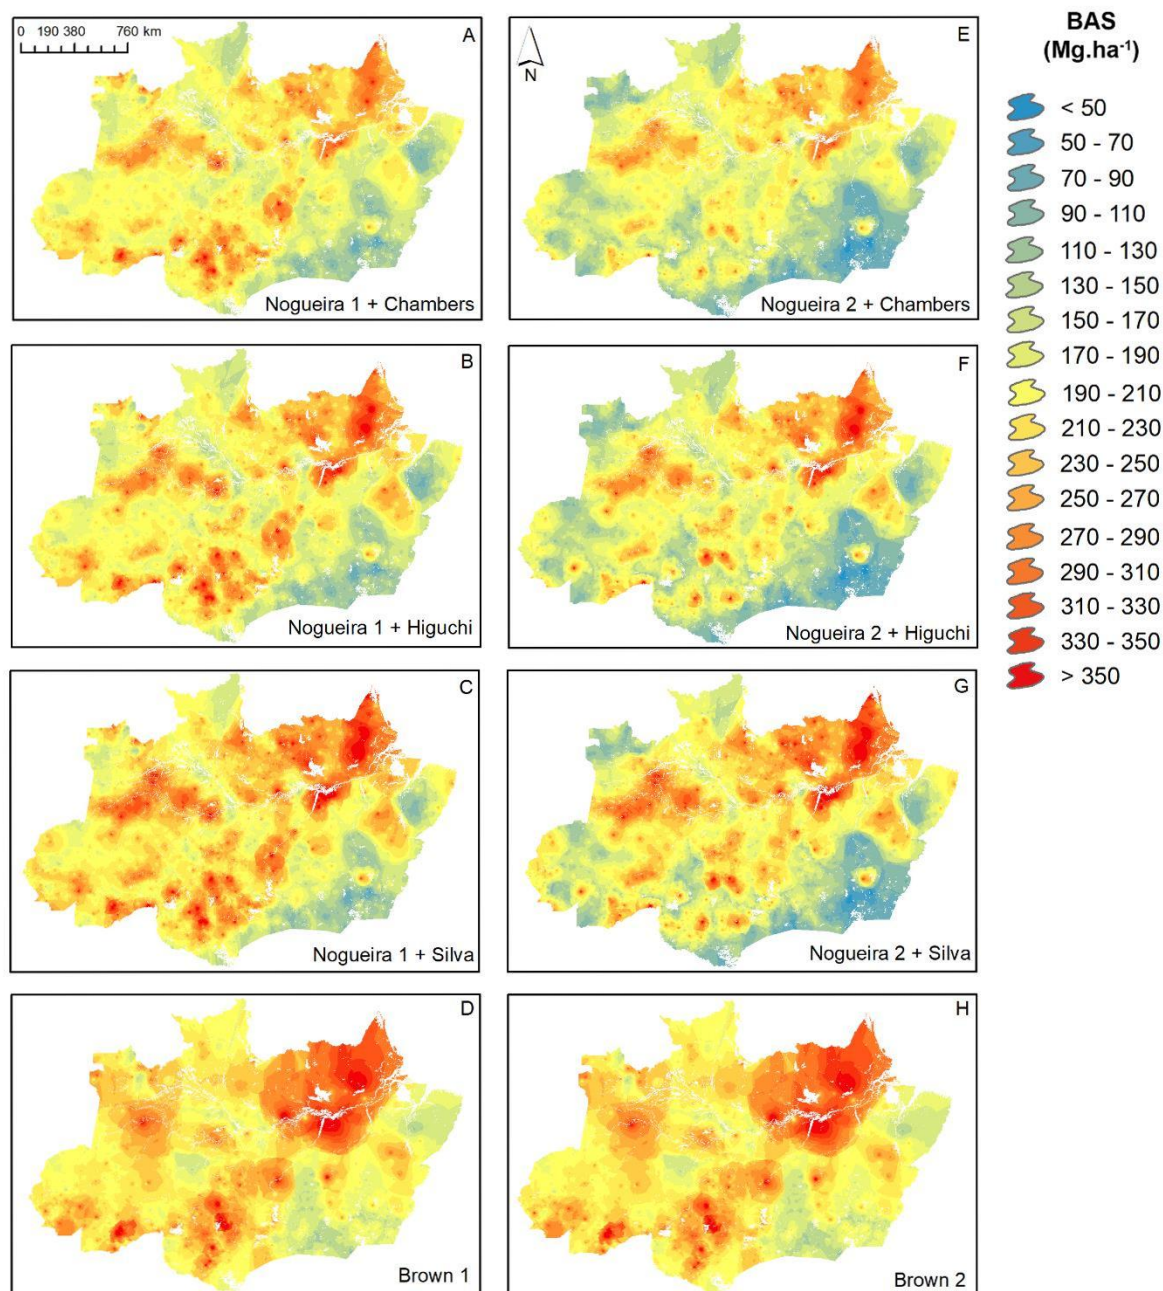
Para o mapa de distribuição de biomassa por hectare gerado, utilizando um fator de expansão para incluir árvores com $10 \leq \text{DAP} < 30$ cm, além de árvores com $\text{DAP} \geq 30$ cm, observam-se maiores valores e absolutos de biomassa por unidade de área, bem como maiores concentrações de valores altos biomassa em regiões mais distribuídas do bioma Amazônia (FIGURA 27).

Em comparação, os resultados aqui expostos – com ênfase nas FIGURAS 27.B, 27.C, 27.D, 27.E e 27.H - se assemelham ao mapa elaborado por Nogueira et al. (2008), no qual os autores geraram um mapa de biomassa para o bioma Amazônia a partir de dados do Projeto RADAMBRASIL. Dessa forma, é possível observar maiores concentrações de biomassa por unidade de área nas regiões sudoeste, central e, principalmente, na região nordeste do bioma Amazônia (norte do estado do Pará e estado do Amapá). Outra comparação pode ser feita com mapas referência de biomassa e carbono para florestas tropicais (SAATCHI et al., 2011; AVITABILE et al., 2016). Saatchi et al. (2011, FIGURA 2.A) reportaram uma concentração de valores de biomassa por unidade de área entre 200-350 Mg ha⁻¹. Avitabile et al. (2016, FIGURA 3), em trabalho mais recente, indicaram que os estoques de biomassa se concentram entre 150-400 Mg ha⁻¹. Portanto, resultados semelhantes aos aqui reportados (FIGURA 27).

Tal qual observado na FIGURA 26, maiores valores de biomassa por hectare foram observados a partir da equação de Silva (2007), em combinação com dados de floresta aberta (FIGURAS 27.C e 27.G). Em contrapartida, a partir da equação de Chambers et al. (2001), em combinação com dados de floresta aberta, observou-se menores valores de biomassa estimados (FIGURAS 27.A e 27.E). Já na distribuição da biomassa a partir das equações de Higuchi et al. (1998) e Nogueira et al. (2008), observam-se maiores concentrações de biomassa por unidade de área nas regiões central e nordeste do bioma Amazônia, além de focos de concentração no sul do estado do Amazonas e estado de Rondônia (FIGURAS 27.B e 27.F)

Ambos os mapas gerados a partir das equações de Brown (1997) indicaram maiores valores de biomassa por unidade de área, em comparação com os demais mapas de distribuição de biomassa gerados (FIGURAS 27.D e 27.H). Dessa forma, denota-se novamente superestimativas nos valores de biomassa aérea de árvores obtidas por meio das equações genéricas, quando comparado aos valores obtidos por meio de equações específicas para as tipologias floresta densa e floresta aberta.

FIGURA 27 – MAPAS DE BIOMASSA FLORESTAL ACIMA DO SOLO (BAS), PARA FLORESTA Densa E FLORESTA ABERTA NO BIOMA AMAZÔNICO BRASILEIRO, A PARTIR DE DADOS DE INVENTÁRIO FLORESTAL DO PROJETO RADAMBRASIL, COM CÁLCULO CONSIDERANDO FATOR DE EXPANSÃO PARA INCLUSÃO DE ÁRVORES COM $10 \leq \text{DAP} < 30 \text{ cm}$: A. Chambers et al. (2001) e Nogueira et al. (2008) Equação 1; B. Higuchi et al. (1998) e Nogueira et al. (2008) Equação 1; C. Silva (2007) e Nogueira et al. (2008) Equação 1; D. Brown (1997) Equação 1; E. Chambers et al. (2001) e Nogueira et al. (2008) Equação 2; F. Higuchi et al. (1998) e Nogueira et al. (2008) Equação 2; G. Silva (2007) e Nogueira et al. (2008) Equação 2; H. Brown (1997) Equação 2.

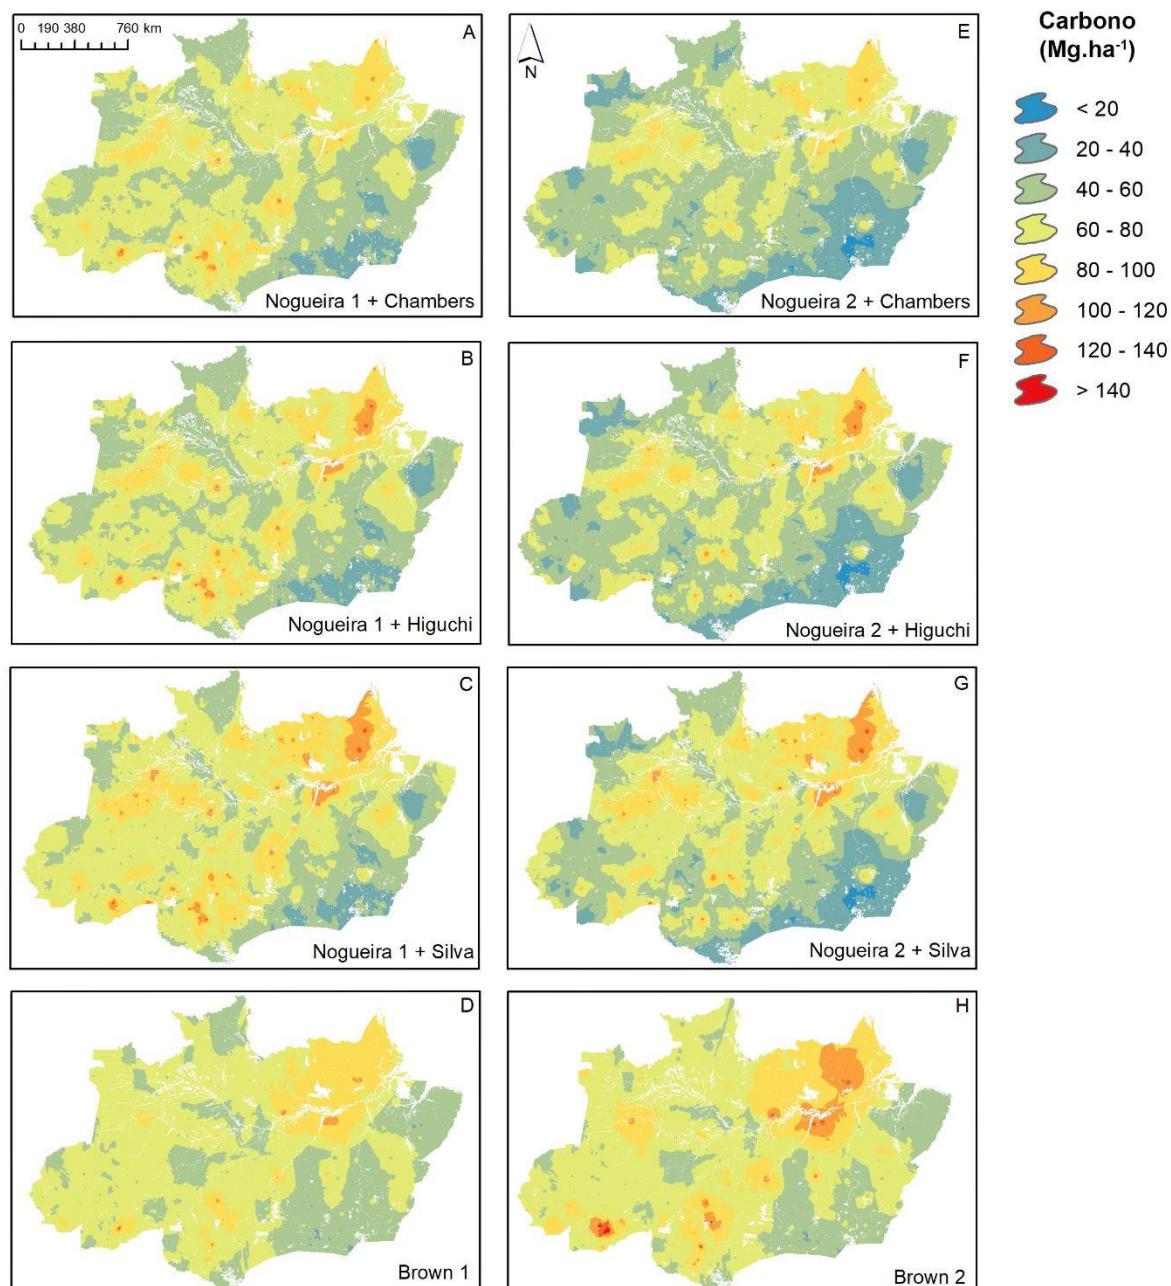


FONTE: A AUTORA (2021).

Para o mapa de distribuição de carbono acima do solo, considerando árvores com DAP ≥ 30 cm (FIGURA 28), nota-se um resultado semelhante ao observado na FIGURA 26, em termos de concentração dos estoques de carbono. Observa-se um predomínio de concentração de carbono entre os valores de 40-100 Mg ha⁻¹, além de algumas regiões com valores que atingem 100-140 Mg ha⁻¹ e poucos pontos em que a concentração de carbono ultrapassa 140 Mg ha⁻¹. Além disso, para os mapas gerados a partir das combinações de estimativas a partir das equações de Chambers et al. (2001) e Higuchi et al. (1998) com equações de floresta aberta (FIGURAS 28.A, 28.B, 27.E e 27.F), nota-se nas regiões centro-oeste e sudoeste o predomínio de concentrações de valores mais baixos de carbono acima do solo, variando entre < 20 até 60 Mg ha⁻¹.

As estimativas obtidas pela equação de Silva (2007) em combinação com dados de floresta aberta, apresentaram maior distribuição de carbono por hectare acima de 100 Mg ha⁻¹, concentrados nas regiões sul (estados do Amazonas e Rondônia) e nordeste do bioma Amazônia (estados do Pará e Amapá) (FIGURAS 28.C e 28.G). Os resultados observados a partir da equação de Chambers et al. (2001), em combinação com dados de floresta aberta (FIGURAS 28.A e 28.E), indicaram menores valores de biomassa estimados, em comparação com os demais mapas de distribuição de carbono. A distribuição da biomassa a partir das equações de Higuchi et al. (1998) e Nogueira et al. (2008) (FIGURAS 28.B e 28.F) concentrou-se nas regiões nordeste (estados do Pará e Amapá), sul (Amazonas, Roraima) e na central (Amazonas) do bioma Amazônia. Os mapas gerados a partir das equações de Brown (1997) indicaram maiores valores de biomassa por unidade de área, denotada nas regiões nordeste e sul do bioma Amazônia.

FIGURA 28 – MAPAS DE CARBONO FLORESTAL ACIMA DO SOLO, PARA FLORESTA DENSE E FLORESTA ABERTA NO BIOMA AMAZÔNICO BRASILEIRO, A PARTIR DE DADOS DE INVENTÁRIO FLORESTAL DO PROJETO RADAMBRASIL, PARA ÁRVORES COM DAP ≥ 30 cm: A. Chambers et al. (2001) e Nogueira et al. (2008) Equação 1; B. Higuchi et al. (1998) e Nogueira et al. (2008) Equação 1; C. Silva (2007) e Nogueira et al. (2008) Equação 1; D. Brown (1997) Equação 1; E. Chambers et al. (2001) e Nogueira et al. (2008) Equação 2; F. Higuchi et al. (1998) e Nogueira et al. (2008) Equação 2; G. Silva (2007) e Nogueira et al. (2008) Equação 2; H. Brown (1997) Equação 2.



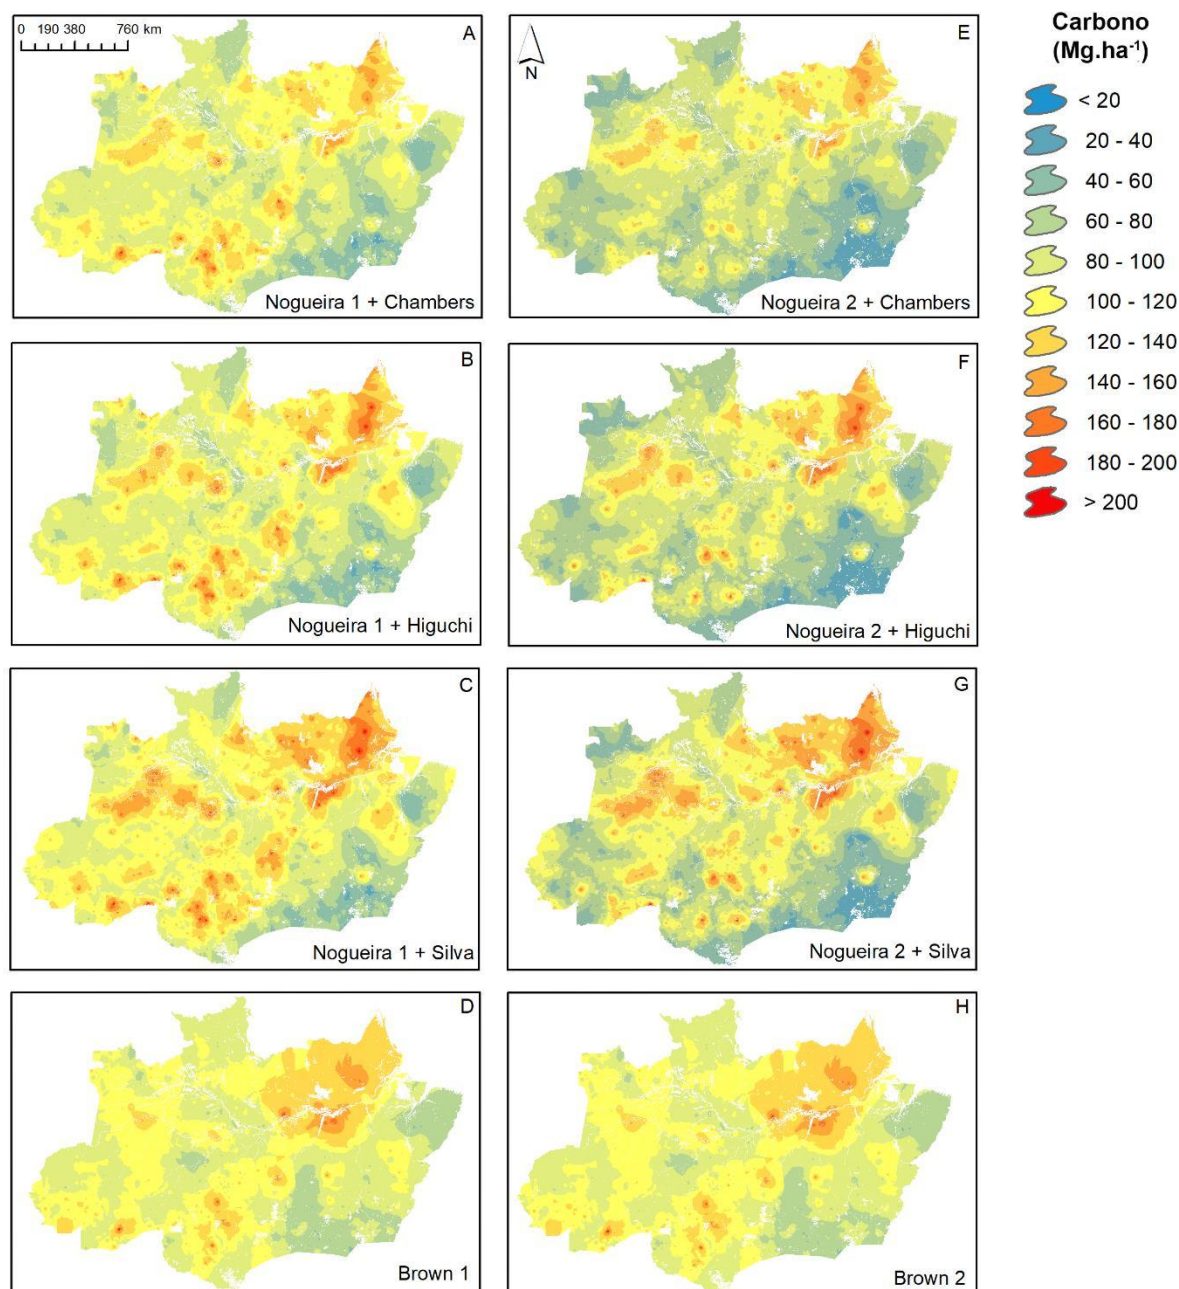
FONTE: A AUTORA (2021).

A partir do mapa de distribuição de carbono por hectare, utilizando um fator de expansão para incluir árvores com $10 \leq \text{DAP} < 30$ cm, além de árvores com $\text{DAP} \geq 30$ cm (FIGURA 29), observa-se uma maior concentração dos estoques de carbono acima do solo nas regiões central (estado do Amazonas), sul (Rondônia e sul do Amazonas) e nordeste (Amapá e norte do Pará) do bioma Amazônia.

Os resultados observados na FIGURA 29 evidenciam similaridades entre os valores de carbono estocado por unidade de área e padrões de distribuição com aqueles encontrados na literatura, em mapas referência de biomassa e carbono para florestas tropicais (SAATCHI et al., 2011; BACCINI et al., 2012). Saatchi et al. (2011, FIGURA 3.A) encontraram valores de estoques totais de carbono acima do solo, para a floresta amazônica brasileira, entre 12 e $>200 \text{ Mg ha}^{-1}$, com concentração de estoques entre $80\text{-}200 \text{ Mg ha}^{-1}$. Resultados semelhantes são observados nas FIGURAS 29.A-C (combinação de estimativas de equações de floresta densa e aberta) e nas FIGURAS 29.D e 29.H (estimativas a partir de equações genéricas para ambientes tropicais). Baccini et al. (2012, FIGURA 1) reportaram que os estoques de carbono na floresta amazônica, com destaque para as regiões central e nordeste do bioma, concentram-se entre $100\text{-}150 \text{ Mg ha}^{-1}$, tal qual observado na presente análise.

Em outra comparação, o mapa de carbono aqui apresentado se assemelha ao reportado no Terceiro Inventário Brasileiro de Emissões e Remoções Antrópicas de GEEs (MCTI, 2015. FIGURA 22.A). Neste, mapas de biomassa e carbono foram gerados a partir de dados do RADAMBRASIL, sendo que os estoques de carbono acima do solo variaram, aproximadamente, entre $70\text{-}200 \text{ Mg ha}^{-1}$, com concentração, principalmente, nas regiões central (estado do Amazonas), sul (sul do Amazonas e norte de Rondônia) e nordeste (Amapá e norte do Pará) do bioma Amazônia. Novamente, análise semelhante pode ser feita a partir dos resultados encontrados na FIGURA 29.

FIGURA 29 – MAPAS DE CARBONO FLORESTAL ACIMA DO SOLO, PARA FLORESTA DENSA E FLORESTA ABERTA NO BIOMA AMAZÔNICO BRASILEIRO, A PARTIR DE DADOS DE INVENTÁRIO FLORESTAL DO PROJETO RADAMBRASIL, COM CÁLCULO CONSIDERANDO FATOR DE EXPANSÃO PARA INCLUSÃO DE ÁRVORES COM $10 \leq \text{DAP} < 30 \text{ cm}$: A. Chambers et al. (2001) e Nogueira et al. (2008) Equação 1; B. Higuchi et al. (1998) e Nogueira et al. (2008) Equação 1; C. Silva (2007) e Nogueira et al. (2008) Equação 1; D. Brown (1997) Equação 1; E. Chambers et al. (2001) e Nogueira et al. (2008) Equação 2; F. Higuchi et al. (1998) e Nogueira et al. (2008) Equação 2; G. Silva (2007) e Nogueira et al. (2008) Equação 2; H. Brown (1997) Equação 2.



FONTE: A AUTORA (2021).

A partir dos mapas de biomassa e carbono gerados, obteve-se os seguintes estoques totais de biomassa aérea e carbono aéreo de árvores para o bioma Amazônia, a partir das equações específicas de floresta densa e floresta aberta (TABELA 21): 46,5 Gt (1 Gt = 1 bilhão de megagramas), para o mapa da FIGURA 26; 74,95 Gt, para o mapa da FIGURA 27; 23,38 Gt, para o mapa da FIGURA 28; e 35,88 Gt, para o mapa da FIGURA 29.

TABELA 21 – BIOMASSA ACIMA DO SOLO (BAS) ESTIMADA PARA O BIOMA AMAZÔNIA, EM GIGATONELADAS (Gt), A PARTIR DE EQUAÇÕES DE BIOMASSA DE FLORESTA DENSE E FLORESTA ABERTA E EQUAÇÕES GENÉRICAS PARA FLORESTAS TROPICAIS.

Equações	BAS (Gt) – FIGURA 26	BAS (Gt) – FIGURA 27	Carbono (Gt) – FIGURA 28	Carbono (Gt) – FIGURA 29
Nogueira et al. (2008) Equação 1 + Chambers et al. (2001)	47,21	75,92	23,74	36,34
Nogueira et al. (2008) Equação 1 + Higuchi et al. (1998)	48,61	78,18	24,44	37,43
Nogueira et al. (2008) Equação 1 + Silva (2007)	51,76	83,31	26,03	39,89
Nogueira et al. (2008) Equação 2 + Chambers et al. (2001)	41,53	67,06	20,87	32,09
Nogueira et al. (2008) Equação 2 + Higuchi et al. (1998)	43,13	69,66	21,67	33,34
Nogueira et al. (2008) Equação 2 + Silva (2007)	46,76	75,54	23,51	36,16
Brown (1997) Equação 1	49,71	80,46	24,98	38,53
Brown (1997) Equação 2	53,55	86,68	26,96	41,51

FONTE: A AUTORA (2021).

A biomassa total para o bioma Amazônia, estimada a partir das equações de Brown (1997), genéricas para florestas tropicais, foi igual a 51,63 Gt e 83,57 Gt, para os mapas das FIGURAS 26 e 27, respectivamente. Já os estoques totais de carbono aéreo, para as mesmas equações, foram iguais a 25,97 Gt (FIGURA 28) e 40,02 Gt (FIGURA 29).

De acordo com o último relatório FRA (Global Forest Resources Assessment) (FAO, 2020), publicado pela FAO (Organização das Nações Unidas para a Alimentação e a Agricultura), o valor estimado de biomassa acima do solo para

Amazônia brasileira, no ano de 1990, era 87,3 Gt, considerando uma cobertura florestal de 3.766.316,82 km² (<https://mapbiomas.org>; COLEÇÃO 4.1).

Para o cenário 1 (FIGURA 26) os valores totais encontrados para as equações específicas de floresta densa e floresta aberta corresponderam a 54,1% (Nogueira et al., 2008 Equação 1 e Chambers et al., 2001), 55,7% (Nogueira et al., 2008 Equação 1 e Higuchi et al., 1998), 59,3% (Nogueira et al., 2008 Equação 1 e Silva, 2007), 47,6% (Nogueira et al., 2008 Equação 2 e Chambers et al., 2001), 49,4% (Nogueira et al., 2008 Equação 2 e Higuchi et al., 1998) e 53,6% (Nogueira et al., 2008 Equação 2 e Silva, 2007) do valor total reportado pelo FRA.

Portanto, os valores aqui encontrados correspondem, em média, a 53% da biomassa total estimada para todo o bioma Amazônia no Brasil. Com relação aos valores obtidos por meio de Brown (1997) Equação 1 e Brown 1997 Equação 2, genéricas para ambientes tropicais, os valores encontrados correspondem a 56,9% e 61,3%, respectivamente, da biomassa total estimada para o bioma Amazônia. Em comparação com a biomassa obtida por meio de equações específicas para tipologias florestais, as equações de Brown (1997) resultaram em um valor 11% maior em Gt.

Já para o cenário 3 (FIGURA 28) os valores totais de biomassa encontrados para as equações específicas de floresta densa e floresta aberta corresponderam a 55,1% (Nogueira et al., 2008 Equação 1 e Chambers et al., 2001), 56,7% (Nogueira et al., 2008 Equação 1 e Higuchi et al., 1998), 60,4% (Nogueira et al., 2008 Equação 1 e Silva, 2007), 48,4% (Nogueira et al., 2008 Equação 2 e Chambers et al., 2001), 50,3% (Nogueira et al., 2008 Equação 2 e Higuchi et al., 1998) e 54,5% (Nogueira et al., 2008 Equação 2 e Silva, 2007) do valor total reportado pelo FRA. Com relação aos valores obtidos por meio de Brown (1997) Equação 1 e Brown 1997 Equação 2, genéricas para ambientes tropicais, os valores encontrados correspondem a 58% e 62,6%, respectivamente, da biomassa total estimada para o bioma Amazônia.

Ainda, de acordo com o último relatório FRA, publicado pela FAO (Organização das Nações Unidas para a Alimentação e a Agricultura), o valor estimado de carbono estocado acima do solo para Amazônia brasileira, no ano de 1990, era 43,1 Gt (FAO, 2020). Portanto, para o cenário 2 (FIGURA 27) os valores totais encontrados para as equações específicas de floresta densa e floresta aberta corresponderam a 87% (Nogueira et al., 2008 Equação 1 e Chambers et al., 2001), 89,6% (Nogueira et al., 2008 Equação 1 e Higuchi et al., 1998), 95,4% (Nogueira et al., 2008 Equação 1 e Silva, 2007), 76,8% (Nogueira et al., 2008 Equação 2 e Chambers et al., 2001), 79,8%

(Nogueira et al., 2008 Equação 2 e Higuchi et al., 1998) e 86,5% (Nogueira et al., 2008 Equação 2 e Silva, 2007) do valor total reportado pelo FRA. Com relação aos valores obtidos por meio de Brown (1997) Equação 1 e Brown 1997 Equação 2, genéricas para ambientes tropicais, os valores encontrados correspondem a 92,2% e 99,3%, respectivamente, da biomassa total estimada para o bioma Amazônia.

Por fim, de acordo com a análise do cenário 4 (FIGURA 29) - com cálculo de carbono estocado considerando fator de expansão para inclusão de árvores com $10 \leq \text{DAP} < 30 \text{ cm}$ -, os valores totais encontrados para as equações específicas de floresta densa e floresta aberta corresponderam a 84,3% (Nogueira et al., 2008 Equação 1 e Chambers et al., 2001), 86,8% (Nogueira et al., 2008 Equação 1 e Higuchi et al., 1998), 92,6% (Nogueira et al., 2008 Equação 1 e Silva, 2007), 74,5% (Nogueira et al., 2008 Equação 2 e Chambers et al., 2001), 77,4% (Nogueira et al., 2008 Equação 2 e Higuchi et al., 1998) e 83,9% (Nogueira et al., 2008 Equação 2 e Silva, 2007) do valor total reportado pelo FRA. Com relação aos valores obtidos por meio de Brown (1997) Equação 1 e Brown 1997 Equação 2, genéricas para ambientes tropicais, os valores encontrados correspondem a 89,4% e 96,3%, respectivamente, da biomassa total estimada para o bioma Amazônia.

4.2.5.1 Comparações de estoques de biomassa por hectare

Nesse estudo, foi avaliada uma área de 2.863.672,31 km², considerando apenas as tipologias floresta densa e floresta aberta no bioma Amazônia, excluindo-se áreas de campinas, campinaranas, savanas e florestas aluviais, com base no Mapa de Regiões Fitoecológicas do IBGE. Na presente análise foram considerados apenas indivíduos arbóreos, com $\text{DAP} \geq 30 \text{ cm}$, justificando os menores valores de biomassa encontrados, em gigatoneladas, para o bioma Amazônia.

Observa-se na TABELA 22 os valores de biomassa acima do solo, por unidade de área, encontrados nos principais estudos já publicados (SAATCHI et al., 2011; BACCINI et al., 2012; MCTI, 2015; FAO, 2020). Ressalta-se que os valores encontrados no relatório FRA (FAO, 2020) e no relatório do Terceiro Inventário Brasileiro de Emissões e Remoções Antrópicas de Gases de Efeito Estufa (MCTI, 2015) reportam valores de biomassa por tipologia florestal, tal qual procedido neste trabalho.

TABELA 22 – COMPARAÇÕES DE ESTIMATIVAS DE BIOMASSA ACIMA DO SOLO (BAS) PARA A AMAZÔNIA BRASILEIRA E PARA FLORESTAS TROPICAIS, REPORTADAS NA LITERATURA.

Autores	Tipologia florestal	BAS (Mg ha⁻¹)
MCTI (2015)	Amazônia brasileira/ Floresta densa	273,79
MCTI (2015)	Amazônia brasileira/ Floresta aberta	231,71
FAO (2020)	Amazônia brasileira / Floresta densa	267,56
FAO (2020)	Amazônia brasileira/ Floresta aberta	230,06
Saatchi et al. (2011)	Florestas tropicais	255,00
Baccini et al. (2012)	Florestas tropicais	285,50
Este estudo – Figura 26 (PIVA, 2021)	Amazônia brasileira/ Floresta densa	158,14
Este estudo – Figura 26 (PIVA, 2021)	Amazônia brasileira/ Floresta aberta	107,14

FONTE: A AUTORA (2021).

No relatório publicado pelo governo brasileiro (MCTI, 2015) podem ser observados os maiores valores de biomassa total acima do solo (273,69 Mg ha⁻¹ e 231,71 Mg ha⁻¹, para floresta densa e floresta aberta, respectivamente). Esses valores podem ser justificados pelo uso de fatores de expansão de biomassa para inclusão da biomassa de árvores com 10 cm ≤ DAP < 30 cm, além fatores de expansão para inclusão de palmeiras, cipós, sub-bosque, madeira morta, serapilheira e estrato herbáceo. No relatório do FRA, valores de 267,56 Mg ha⁻¹ (floresta densa) e 230,06 Mg ha⁻¹ (floresta aberta) remetem às estimativas de biomassa viva acima do solo, incluindo indivíduos arbóreos e não arbóreos. A partir de mapas pantropicais de biomassa, publicados por Saatchi et al. (2011) e Baccini et al. (2012), valores médios

de biomassa, sem distinção por tipologias florestais, assemelham-se aos resultados reportados pelo FRA, para a biomassa acima de solo, para todos os compartimentos e indivíduos vivos: 255 Mg ha⁻¹ e 285,5 Mg ha⁻¹, respectivamente.

Portanto, observa-se que os valores de biomassa reportados no presente trabalho encontram-se abaixo dos valores encontrados nos demais estudos. Essas diferenças podem ser explicadas por três fatores, relativos à abordagem metodológica do presente estudo: 1. Inclusão apenas de indivíduos arbóreos, com DAP \geq 30 cm; 2. Não utilização de fatores de expansão, para incluir árvores com diâmetro $<$ 30 cm, além dos demais compartimentos acima do solo (tais como palmeiras, cipós, serapilheira e sub-bosque); 3. Área de cobertura considerada, na qual não foram consideradas áreas aluviais, áreas de ecossistemas não-florestais - tais como savanas e campinas (vegetação sobre areia branca) -, ou áreas de contato entre não-floresta e formações florestais. Entretanto, ressalta-se que os valores encontrados no presente estudo, para as tipologias floresta densa e floresta aberta, consistem em um reporte inédito para biomassa aérea de árvores no bioma Amazônia, considerando dados de inventário do Projeto RADAMBRASIL, os quais podem ser utilizados para fins de comparação com os valores de biomassa encontrados nos demais estudos citados.

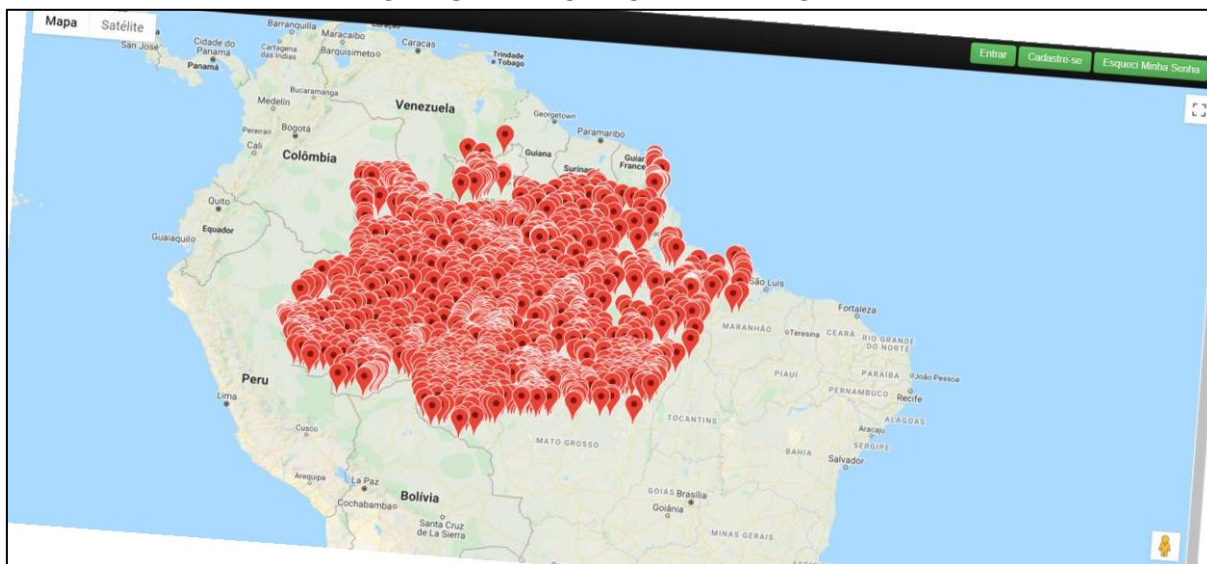
Mapas da distribuição da biomassa para a floresta amazônica e regiões pantropicais têm sido elaborados por meio de três principais métodos: 1. Extrapolações diretas de dados de campo, multiplicando a área total da floresta por valores médios de densidade de biomassa (FEARNSIDE, 1997a; NOGUEIRA et al., 2008); 2. Combinação de sensoriamento remoto (dados LiDAR) com dados de campo (SAATCHI et al., 2011; BACCINI et al., 2012; AVITABILE et al., 2016); 3. Interpolação por meio de krigagem geoestatística (MALHI et al., 2006; MCTI, 2015). No presente estudo, o cálculo de estimativas de biomassa e carbono, realizado partir de equações de biomassa específicas para as tipologias florestais floresta densa e floresta aberta, possibilitou uma nova abordagem de espacialização da biomassa. Esta metodologia mostrou-se eficaz para elaborar mapas de biomassa possibilitando uma abordagem de espacialização de biomassa na floresta amazônica, a partir da interpolação de valores estimados por meio de equações de biomassa.

4.3 INTEGRAÇÃO COM O SOFTWARE JCARBON®

Ao total, foram importados dados de 127.927 árvores, distribuídas em 2.214 parcelas de inventário florestal, para as tipologias floresta densa e floresta aberta, sendo: 1. Dados de 13.696 árvores, em 202 parcelas, para dados do Projeto Paisagens Sustentáveis, da EMBRAPA; 2. Dados de 114.231, em 2.012 parcelas, para dados do Projeto RADAMBRASIL.

A importação dos dados atendeu um dos objetivos propostos neste trabalho, de tal maneira que as informações adicionadas enriqueceram a base de dados do JCarbon®, para locais onde não havia informações catalogadas de estimativas de biomassa, como é o caso da região abrangida pelo bioma Amazônia. Tal constatação pode ser observada na Figura 30, que ilustra a interface do software JCarbon®. Portanto, esta nova versão do software JCarbon® - uma iniciativa pioneira - constitui uma plataforma inédita e *open data* com dados de estimativas de biomassa por parcela, a partir de duas grandes bases de dados de inventários florestais no bioma Amazônia.

FIGURA 30 – TELA INICIAL DO SOFTWARE JCARBON®, COM INDICAÇÃO DOS LOCAIS (PONTOS EM VERMELHO) DAS PARCELAS DE INVENTÁRIO FLORESTAL NO BIOMA AMAZÔNIA.



FONTE: A AUTORA (2021).

A integração dos resultados do presente trabalho com o software JCarbon® permite que qualquer usuário do Brasil e do mundo possa acessar e compartilhar as

informações de estoques de biomassa por parcela de inventário florestal no bioma Amazônia, constituindo, portanto, uma plataforma *open data*.

4.4 COMPARAÇÕES DE ESTOQUES DE BIOMASSA OBTIDOS POR MEIO DE EQUAÇÕES DE BIOMASSA, DADOS LIDAR E ALGORITMOS DE APRENDIZADO DE MÁQUINA

4.4.1 Análise descritiva dos dados

A descrição da base de dados, utilizada para fins de comparação dos estoques de biomassa obtidos por meio de equações de biomassa, dados LiDAR e algoritmos de aprendizado de máquina ($n = 2.304$ árvores), está apresentada na TABELA 23:


TABELA 23 – DESCRIÇÃO DA BASE DE DADOS. LOCALIDADE: FAZENDA CAUAXI, PARAGOMINAS, PARÁ. DADOS EXTRAÍDOS DO PROJETO PAISAGENS SUSTENTÁVEIS DA EMBRAPA.

Variável	Valor mínimo	Valor máximo	Média	Desvio padrão
Diâmetro à altura do peito (cm)	10,0	200,0	36,11	20,73
Altura total (m)	2,31	71,22	26,20	10,23
Densidade da madeira (g cm^{-3})	0,27	1,06	0,74	0,14

FONTE: A AUTORA (2021).

Os valores de DAPs variaram de 10-200 centímetros, com média igual a 36,11 cm, e desvio padrão de 20,73 cm. Pode-se observar que a distribuição diamétrica dos dados segue o padrão decrescente, em forma de “J invertido”, característico de florestas tropicais (FIGURA 31). Os DAPs das árvores na área de estudo concentraram-se entre 10-50 cm (1.829 indivíduos, o que representa, aproximadamente, 79% do número total de indivíduos). Observa-se, ainda, que 698 árvores apresentam entre 10-20 cm de DAP, intervalo que concentra o maior número de indivíduos.


FIGURA 31 – DISTRIBUIÇÃO DIAMÉTRICA DAS ÁRVORES NA ÁREA DE ESTUDO. LOCALIDADE: FAZENDA CAUAXI, PARAGOMINAS, PARÁ. DADOS EXTRAÍDOS DO PROJETO PAISAGENS SUSTENTÁVEIS DA EMBRAPA. LINHA PONTILHADA NA VERTICAL REPRESENTA A MÉDIA ARITMÉTICA.



FONTE: A AUTORA (2021).

A distribuição das alturas das árvores na área de estudo varia de 2,31 a 71,22 metros, com valor médio igual a 26,20 m e desvio padrão de 10,23 m. Observa-se também que a altura das árvores se concentra entre os valores de 26 e 34 metros (FIGURA 32), com frequência de 688 indivíduos. Também se observa alta frequência de indivíduos com alturas entre 15-24 metros (611 indivíduos). A densidade da madeira das 107 espécies ocorrentes na área de estudo variou de 0,27 a 1,06 g cm⁻³, com valor médio de 0,76 g cm⁻³ e desvio padrão igual a 0,14 g cm⁻³.

FIGURA 32 – DISTRIBUIÇÃO DAS ALTURAS DAS ÁRVORES NA ÁREA DE ESTUDO. LOCALIDADE: FAZENDA CAUAXI, PARAGOMINAS, PARÁ. DADOS EXTRAÍDOS DO PROJETO PAISAGENS SUSTENTÁVEIS DA EMBRAPA. LINHA PONTILHADA NA VERTICAL REPRESENTA A MÉDIA ARITMÉTICA




FONTE: A AUTORA (2021).

A relação entre os valores de diâmetro e altura das árvores na área de estudo segue uma tendência de distribuição inferindo uma linha curva polinomial, como pode ser observado na FIGURA 33. Observa-se uma heterogeneidade tanto nos valores de diâmetro quanto de altura das árvores, sendo uma característica de florestas tropicais, onde há também grande variação tanto em termos de idade como de espécies (MACHADO; FIGUEIREDO FILHO, 2003).

Comportamento semelhante foi encontrado por Feldpausch et al. (2011, FIGURA 4) e Barbosa et al. (2019, FIGURA 4), ao caracterizaram a relação entre valores de diâmetro à altura do peito e altura total de árvores em localidades na floresta amazônica.

FIGURA 33 – RELAÇÃO ENTRE OS DIÂMETROS E AS ALTURAS DAS ÁRVORES NA ÁREA DE ESTUDO. LOCALIDADE: FAZENDA CAUAXI, PARAGOMINAS, PARÁ. DADOS EXTRAÍDOS DO PROJETO PAISAGENS SUSTENTÁVEIS DA EMBRAPA.



FONTE: A AUTORA (2021).

4.4.2 Estimativas de biomassa por meio do aplicativo web MLMBio

As estimativas de biomassa para a localidade Fazenda Cauaxi, Pará, para 22 parcelas de inventário florestal, foram, em média, iguais a 207,47 Mg ha⁻¹, 212,15 Mg ha⁻¹, 236,42 Mg ha⁻¹, obtidas a partir dos modelos de Random Forest, ANN (Artificial Neural Network) e pantropical (CHAVE et al., 2014), respectivamente (TABELA 24). Os valores totais de biomassa para as 22 parcelas foram 5.201,15, 4.667,37, e 4.564,40 Mg, calculados a partir do modelo pantropical, do modelo ANN e do modelo Random Forest, respectivamente.

Observou-se que estimativas de biomassa obtidas por meio da equação alométrica ajustada a partir do modelo pantropical de Chave et al. (2014) foram superiores, para todas as parcelas avaliadas, quando comparadas às estimativas por meio de equações ajustadas a partir de modelos de aprendizado de máquina (ANN e Random Forest). Dessa forma, valores estimados pela equação pantropical foram 6,6% (Parcela T21, equação ANN) a 27,7% (parcela T04, modelo Random Forest)

superiores aos valores obtidos pelos modelos ANN e Random Forest, variando de acordo com a parcela analisada.

TABELA 24 – RESULTADOS DAS ESTIMATIVAS DE BIOMASSA ACIMA DO SOLO (BAS) POR PARCELA, EM Mg ha⁻¹, OBTIDAS A PARTIR DO MODELO ALOMÉTRICO DE CHAVE et al. (2014), MODELOS ANN E RANDOM FOREST E DA EQUAÇÃO DE D’OLIVEIRA ET AL. (2012).

Parcela	BAS: Modelo Pantropical (Mg ha⁻¹)	BAS: Modelo ANN (Mg ha⁻¹)	BAS: Modelo Random Forest (Mg ha⁻¹)	BAS: d’Oliveira et al. (2012) (Mg ha⁻¹)
T01	190,33	173,06	167,18	296,42
T02	223,38	202,92	195,31	322,64
T03	265,29	241,77	243,42	296,34
T04	302,84	236,56	218,89	242,40
T05	186,62	167,60	172,43	275,79
T06	256,41	230,00	226,62	284,07
T07	349,57	317,01	308,92	365,24
T08	317,83	278,47	280,67	338,21
T09	325,12	296,99	290,12	365,49
T10	180,97	165,15	162,46	262,93
T11	221,08	203,18	199,40	271,54
T12	236,27	215,87	212,10	237,03
T13	251,33	227,31	220,54	349,31
T14	247,77	222,78	211,78	346,03
T15	242,04	218,62	215,38	357,60
T16	197,60	179,27	171,15	320,59
T17	170,83	152,56	164,95	214,81
T18	222,42	200,22	198,21	259,66
T19	161,43	147,55	140,96	200,09
T20	236,99	210,75	198,31	281,61
T21	239,08	223,20	209,24	195,99
T22	175,95	156,51	156,35	345,21
Média	236,42	212,15	207,47	292,23

FONTE: A AUTORA (2021).

Nota-se que a média de biomassa por unidade de área obtida por meio da equação de d'Oliveira et al. (2012) – a partir de métricas LiDAR –, igual a 292,23 Mg ha⁻¹, foi superior à média estimada para as demais equações.


Como detalhado na TABELA 22, os valores de biomassa no bioma Amazônia, para floresta densa variam de 267,56 a 273,79 Mg ha⁻¹ (MCTI, 2015; FAO, 2020). Na presente análise, as estimativas de biomassa obtidas por meio da equação pantropical apresentou valores mais semelhantes aos referenciados na literatura, com média igual a 236,42 Mg ha⁻¹. Em contrapartida, as estimativas obtidas por meio das equações ANN e Random Forest apresentaram valores inferiores de biomassa média por hectare, iguais a 212,15 Mg ha⁻¹ e 207,47 Mg ha⁻¹. No entanto, dentre todas as equações testadas, as estimativas de biomassa obtidas por meio da equação com *inputs* de métricas LiDAR apresentou valor médio mais próximo dos valores encontrados na literatura, com média de biomassa igual a 292,23 Mg ha⁻¹.

Diferenças entre as estimativas dos estoques de biomassa, por parcela, obtidas por meio da equação de d'Oliveira et al. (2012), em comparação com estimativas dos modelos pantropical, ANN e Random Forest, são detalhadas na FIGURA 34.

Observa-se que há um aumento gradual dos valores de biomassa por hectare, ao passo que há um aumento da área basal (m².ha⁻¹) das parcelas analisadas. Valores de biomassa por hectare, com relação à área basal (m².ha⁻¹) obtidos por meio da equação de d'Oliveira et al. (2012) foram, de modo geral, superiores às estimativas obtidas por meio das equações pantropical, ANN e Random Forest. Na comparação equação d'Oliveira et al. (2012) *versus* equação pantropical (FIGURA 34.A), a primeira apresenta valores superiores de biomassa para valores de área basal entre 11-16 m².ha⁻¹, com alguns decaimentos entre 14-15 m².ha⁻¹. Entre valores de 15,5-17 m².ha⁻¹ de área basal, valores de biomassa da equação foram levemente superiores, e, após esse intervalo, os valores da equação de d'Oliveira et al. (2012) voltam a subir, com pequena diferença entre as biomassas obtidas por meio das duas equações.

Na comparação dos valores de biomassa com relação à área basal da equação d'Oliveira et al. (2012) *versus* equação ANN e equação d'Oliveira et al. (2012) (FIGURA 34.B) e *versus* equação Random Forest (FIGURA 34.C), maiores diferenças foram encontradas. Dessa forma, os valores de biomassa por hectare obtidos por meio da equação d'Oliveira et al. (2012) apresentaram superioridade para os intervalos de área basal entre 11-15,5 m².ha⁻¹ e 16-21 m².ha⁻¹.

FIGURA 34 – COMPARAÇÕES DE ESTOQUES DE BIOMASSA POR PARCELA. A. EQUAÇÃO PANTROPICAL E D'OLIVEIRA ET AL. (2012); B. EQUAÇÃO ANN E D'OLIVEIRA ET AL. (2012); C. EQUAÇÃO RANDOM FOREST E D'OLIVEIRA ET AL. (2012).




FONTE: A AUTORA (2021).

Uma análise comparativa entre as estimativas obtidas por meio das equações disponibilizadas pelo aplicativo web MLMBio também foi realizada (FIGURA 35). As estimativas obtidas pela equação pantropical foram superiores que estimativas obtidas por meio das equações ANN e Random Forest (FIGURAS 35.A e 35.B). Maiores diferenças foram encontradas entre as estimativas obtidas pela equação pantropical e pela equação Random Forest (FIGURA 35.B). As estimativas obtidas a partir de modelos de aprendizado de máquina (equações ANN e Random Forest) apresentaram valores semelhantes de biomassa estimada por unidade de área, com relação à área basal das parcelas ($\text{m}^2.\text{ha}^{-1}$) (FIGURA 35.C).

Observa-se – tal qual observado na FIGURA 34 – que os valores de biomassa por hectare aumentam gradualmente, ao passo que há um aumento da área basal ($\text{m}^2.\text{ha}^{-1}$) das parcelas analisadas. Os valores de biomassa obtidos por meio da equação pantropical foram superiores aos valores encontrados por meio das equações ANN e Random Forest, conforme o maior valor de área basal nas parcelas. Além disso, maiores diferenças entre as estimativas de biomassa foram encontradas para maiores valores de área basal ($16\text{-}21 \text{ m}^2.\text{ha}^{-1}$), onde estimativas obtidas por meio da equação pantropical atingiram valor máximo de, aproximadamente, 350 Mg ha^{-1} .

FIGURA 35 – COMPARAÇÕES DE ESTOQUES DE BIOMASSA POR PARCELA. A. EQUAÇÃO PANTROPICAL E EQUAÇÃO ANN; B. EQUAÇÃO PANTROPICAL E EQUAÇÃO RANDOM FOREST; C. EQUAÇÃO PANTROPICAL E D'OLIVEIRA ET AL. (2012).



FONTE: A AUTORA (2021).

Em nível global, estudos sobre o uso de sistemas LiDAR aerotransportados para estimar a altura das árvores, volume do povoamento, área basal, estrutura das árvores (como forma do fuste e índice de área foliar), biomassa florestal, entre outros, se proliferaram no final dos anos 90 (NAESSET, 1997; LEFSKY et al., 1999) e começo dos anos 2000 (LEFSKY et al., 2002). Desde então, a aplicação dessa ferramenta no campo das ciências florestais vem crescendo. Em anos recentes, destaque para o uso de sistemas LiDAR na quantificação de estoques de biomassa e carbono em áreas com grandes extensões territoriais, em diferentes domínios climáticos do globo terrestre, com destaque para ambientes temperados (ZHENG et al., 2007; HUDAK et al., 2012; SIMONSON et al., 2016; NIE et al., 2017). Destaca-se, também, o aumento de estudos em florestas tropicais e, mais especificamente, na floresta amazônica, para estimativas de biomassa florestal utilizando a tecnologia LiDAR (D'OLIVEIRA et al., 2012; TEJADA et al., 2019; REX et al., 2020).

Esse crescente uso de sistemas LiDAR se deve, principalmente, pelo seguinte motivo: apesar das atividades de inventário florestal fornecerem valiosas informações para a geração de estimativas de biomassa e carbono em ecossistemas florestais (ZHENG et al., 2007), configura-se como um método espacialmente limitado (WEST; WEST, 2009). Nesse sentido, os sistemas LiDAR apresentam diversas vantagens em relação a outras técnicas tradicionais de trabalho de campo, pois possibilitam a aquisição de informações em locais de difícil acesso, uso de diferentes escalas, informações homogêneas em escala temporal e informações de livre acesso (CASTILLO et al., 2015).

Também se destaca outras vantagens do uso de sistemas LiDAR nas estimativas de biomassa em grandes extensões territoriais, como é o caso do bioma Amazônia, tais como: 1. Obtenção de estimativas mais acuradas da estrutura florestal, uma vez que fornecem representações em 3D das florestas; 2. Análise da estrutura e dinâmica de sub-bosques (utilizando *laser scanner* terrestre) (VASCONCELLOS, 2020, submetido à publicação); 3. Fornece estimativas diretas do dossel e fração de cobertura florestal (BELAND et al., 2019). Além disso, de acordo com os mesmos autores, permite a coleta de dados de elevação, mesmo em florestas densas, devido à alta capacidade de penetração dos pulsos *laser* (utilizando *laser scanner* aéreo). Ressalta-se, ainda, que os sistemas LiDAR possibilitam a coleta informações de inventários florestais (tais como, altura das árvores, dimensões da copa e estimativas de

volume), como também a coleta de informações da ecologia florestal (tais como, estruturas horizontal e vertical das florestas, trocas gasosas e transpiração das árvores) (MALTAMO et al., 2005; KOETZ et al., 2007; DASSOT; CONSTANT; FOURNIER, 2011).

Neste ponto, adverte-se que a obtenção de informações sobre a estrutura e dinâmica de ecossistemas florestais utilizando sistemas LiDAR ainda é considerado um método custoso operacionalmente e computacionalmente (BELAND et al., 2019), devido à complexidade quando considera-se as etapas de planejamento, coleta, extração das métricas e análise dos dados oriundos das nuvens LiDAR, exigindo capacitação técnica especializada. Entretanto, apesar de ainda ser considerada uma tecnologia de alto custo, está cada vez mais acessível, devido, principalmente, à popularização de veículos aéreos não tripulados (VANTs) com sensores LiDAR embarcados, considerados de baixo custo quando comparado ao custo de sensores embarcados em aeronaves ou a aquisição de equipamentos TLS (*laser scanner* terrestre).

Na análise aqui realizada, observou-se que a equação de d'Oliveira et al. (2012) apresentou valores de biomassa por hectare mais próximos de valores referência da literatura, quando comparada à equação pantropical de Chave et al. (2014) e equações a partir de modelos de aprendizado de máquina. Com base nesse resultado, pode-se inferir que o uso de sistemas LiDAR tem elevado potencial não só para gerar mapas acurados da distribuição da biomassa (SAATCHI et al., 2011; BACCINI et al., 2012; AVITABILE et al., 2016), como também para a obtenção de valores confiáveis de biomassa acima do solo por unidade de área no bioma Amazônia.

Deve-se ressaltar que, na floresta amazônica brasileira, o planejamento de levantamentos florestais para coleta de dados em todos os estados que a compõem, também consiste em uma atividade extremamente desafiadora, uma vez que demanda elevado esforço amostral e mobilização de pessoal, devido às dificuldades de deslocamento e acesso às parcelas de inventário florestal. Portanto, iniciativas tais como as executadas no âmbito do Projeto RADAMBRASIL e, mais recentemente, pelo Inventário Florestal Nacional, também implicam em altos custos operacionais e demasiado tempo para serem concluídos, além de dificuldades referentes à tabulação e análise do grande volume de dados gerados.

Após estas considerações, para a obtenção de estimativas mais acurada de biomassa, com otimização de tempo e redução custos de levantamentos florestais,

indica-se a integração de sistemas LiDAR (*laser scanner* terrestre e *laser scanner* aéreo) com métodos tradicionais de inventários florestais (LEFSKY et al., 2002; HERNÁNDEZ-STEFANONI et al., 2020; VASCONCELOS, 2020, submetido à publicação). Portanto, pode-se dizer que o futuro das ciências florestais e, mais especificamente, do campo da mensuração florestal, está interligado à combinação de levantamentos de campo com dados obtidos a partir de sistemas LiDAR.

Dentro deste tópico de discussão, também há de se destacar a facilidade de uso e praticidade para obtenção de estimativas de biomassa a partir do aplicativo web MLMBio, desenvolvido por Souza (2020). Para tanto, basta que o usuário suba um arquivo de planilha eletrônica, no formato “.csv”, contendo informações de inventário florestal com valores, por árvore, de diâmetro, altura e densidade da madeira. Caso o usuário também possua, em sua base de dados, informações de biomassa observada, nos dados de saída apresentadas pelo MLMBio também constará os valores os cálculos dos resíduos por árvore, além da geração automática do gráfico de resíduos (biomassa observada vs. biomassa estimada). Maiores detalhes acerca da descrição de uso do aplicativo web MLMBio podem ser encontradas em Souza (2020, seção 4.1.7).

Ademais, no trabalho de Souza (2020. p. 85), os dois melhores modelos de aprendizado máquina encontrados para estimativa de biomassa de árvores em florestas tropicais (usando dados de Chave et al, 2014) foram construídos usando os algoritmos ANN (com nove neurônios na camada oculta e uma taxa de decaimento de pesos igual a 0,2) e Random Forest (1.500 árvores, cada uma com 5 divisões - ou seis nós terminais -, com um número mínimo de cinco observações por nó terminal, e uma taxa de aprendizado de 0,01). Além destes, considerados os melhores modelos (ambos inseridos no aplicativo web MLMBio), destaques também para: 1. SVR (Support Vector Regression radial); 2. XGBoost (Extreme Gradient Boosting); 3. M5' (Model Tree); 5. wkNN (Weighted k-Nearest-Neighbor); 6. RF (Random Forest); 7. BT (Bagged Trees); e 8. RT (Regression Trees) (SOUZA, 2020. p. 85).

Constata-se, portanto, que modelos de aprendizado de máquina são eficazes nos cálculos de métricas florestais, tais como volume e biomassa e, por isso, seu uso tem sido cada vez mais difundido nas Ciências Florestais, tal como demonstrado no trabalho de Souza (2020), como também em outros trabalhos recentes (MONTAÑO, 2017; REX, 2019). Portanto, o uso de modelos de aprendizado de máquina para prever valores de biomassa em florestas tropicais apresenta-se como uma

alternativa aos modelos tradicionais, obtidos por meio de regressão linear simples e múltipla.

Entretanto, de maneira geral, tal como observado no trabalho de Souza (2020) os modelos de aprendizado de máquina tiveram desempenho muito similar quando comparados entre si, bem como quando comparados a um modelo de regressão linear, o modelo pantropical, de Chave et al. (2014).

Portanto, pode-se inferir que estimativas por meio de modelos chamados tradicionais, ou seja, equações de biomassa oriundas de modelos de regressão linear, ainda se configuram como uma eficaz alternativa no cálculo de biomassa e carbono em ecossistemas florestais, com menor custo operacional e, principalmente, menor custo computacional do que os métodos anteriormente citados: extração de métricas LiDAR para modelagem de equações de biomassa e modelagem de algoritmos de aprendizado de máquina.

4.4.3 Estimativas de biomassa obtidas por meio de outros algoritmos de aprendizado de máquina

Na análise das estimativas de biomassa obtidas por meio dos sete modelos de aprendizado de máquina, obtidos a partir do trabalho de Souza (2020), resultados semelhantes aos relatados acima foram encontrados. Em geral, as estimativas obtidas por meio destes algoritmos de aprendizado de máquina - treinados a partir do conjunto de dados de Chave et al. (2014) apresentaram resultados muito semelhantes entre si, para as 22 parcelas analisadas (TABELA 25). A partir dos algoritmos de *Regression Trees* (RT), *Model Trees* (M5') e *Support Vector Regression* Radial (SVR), valores levemente superiores de biomassa por hectare foram obtidos, com maior valor médio: 231,48 Mg ha⁻¹, para o modelo M5'; 223,33 Mg ha⁻¹ para o modelo SVR Radial; e 217,40 Mg ha⁻¹ para o algoritmo RT. Por outro lado, os modelos Random Forest (RF) e *Weighted k-Nearest-Neighbor* (wkNN) resultaram em menores valores médios de biomassa por hectare: 194,93 e 198,50 Mg ha⁻¹, respectivamente.

Portanto, de maneira geral, observou-se que os modelos já treinados de aprendizado de máquina tiveram desempenho muito similar quando comparados entre si, bem como quando comparados a um modelo de regressão linear, o modelo pantropical, de Chave et al. (2014) (TABELA 25). Tais semelhanças corroboram com Souza (2020).

TABELA 25 – RESULTADOS DAS ESTIMATIVAS DE BIOMASSA ACIMA DO SOLO (BAS) POR PARCELA, EM Mg ha^{-1} , OBTIDAS A PARTIR DE ALGORITMOS DE APRENDIZADO DE MÁQUINA COM MELHORES DESEMPENHOS, BASEADO NO TRABALHO DE SOUZA (2020).

Parcela	BAS: Modelo SVR (Radial) (Mg ha^{-1})	BAS: Modelo XGBoost (Mg ha^{-1})	BAS: Modelo M5' (Mg ha^{-1})	BAS: Modelo wkNN (Mg ha^{-1})	BAS: Modelo RF (Mg ha^{-1})	BAS: Modelo BT (Mg ha^{-1})	BAS: Modelo RT (Mg ha^{-1})
T01	175,01	166,57	164,97	163,01	160,35	173,22	176,08
T02	207,58	193,78	201,73	193,63	186,18	197,65	201,20
T03	250,18	243,02	247,49	230,85	226,53	212,63	253,35
T04	306,01	223,70	591,95	202,59	204,99	187,87	228,80
T05	176,47	169,57	180,46	162,48	158,45	159,74	177,26
T06	239,82	224,27	230,00	222,09	219,79	230,23	227,56
T07	328,18	300,51	312,88	295,88	284,12	300,51	336,38
T08	296,54	295,63	288,56	260,68	263,54	259,23	295,76
T09	302,73	283,46	295,84	280,81	269,39	272,32	296,40
T10	169,28	161,26	164,37	156,94	155,23	162,43	176,96
T11	208,28	198,04	210,69	190,38	184,01	197,99	213,54
T12	223,16	212,07	217,70	203,34	194,28	187,57	226,56
T13	234,21	219,06	222,08	214,03	208,36	223,22	239,06
T14	228,73	211,70	222,09	213,39	201,86	227,36	222,58
T15	226,75	214,16	230,77	207,98	202,83	213,57	235,13
T16	181,65	169,64	172,37	171,02	164,35	186,86	185,27
T17	162,81	177,66	159,22	137,99	151,05	118,13	168,35
T18	206,75	194,90	203,60	193,36	186,03	200,49	176,08
T19	151,47	140,05	140,69	139,20	135,91	143,25	150,71

T20	235,70	196,43	237,52	181,31	182,62	173,14	209,77
T21	228,41	205,20	215,39	205,28	205,53	221,33	214,49
T22	173,60	156,93	182,18	140,86	142,97	118,72	171,48
Média	223,33	207,16	231,48	198,50	194,93	198,52	217,40

FONTE: A AUTORA (2021).

Em que: SVR = Support Vector Regression; XGBoost = Extreme Gradient Boosting; M5' = Model Tree; wkNN = Weighted k-Nearest-Neighbor; RF = Random Forest; BT = Bagged Trees; RT = Regression Trees.

5 CONCLUSÕES

A integração da base de dados do presente estudo com o software JCarbon[®] foi realizada com êxito, constituindo uma plataforma inédita e *open data* com dados de estimativas de biomassa por parcela, a partir de duas grandes bases de dados de inventários florestais no bioma Amazônia.

Os estoques de biomassa e carbono encontrados para as tipologias floresta densa e floresta aberta indicam a representatividade da biomassa aérea de árvores com DAP ≥ 30 cm nestes ambientes, correspondendo a 53% da biomassa total distribuída no bioma Amazônia, um valor expressivo em termos de análises das mudanças de estoques de biomassa neste bioma.

Além disso, a abordagem de espacialização de biomassa sugerida, utilizando valores obtidos por meio de equações de biomassa para uma extensa base de dados e com ampla distribuição territorial, tem potencial para refinar os mapas de distribuição de biomassa no bioma Amazônia, podendo ser utilizada em estudos futuros.

Comparações entre as estimativas de biomassa por unidade de área (Mg ha^{-1}) obtidas por meio de equações específicas para floresta densa, com estimativas obtidas por equações genéricas de ambientes tropicais indicaram que estas superestimaram em 4,6% os valores de biomassa para esta tipologia. Já com relação às estimativas para floresta aberta, as equações genéricas superestimaram os valores cerca de 33%. Com relação aos valores de biomassa estimada para o bioma, houve um ganho de 11% no valor médio obtido pelas equações específicas, em relação às equações genéricas.

Conclui-se que o uso de equações de biomassa genéricas é inadequado para estimar a biomassa em ecossistemas como bioma Amazônia, caracterizado pela heterogeneidade fitoecológica. Dessa forma, para extensas bases de dados de inventário florestal, como é o caso do Projeto Paisagens Sustentáveis e do Projeto RADAMBRASIL, recomenda-se o uso de equações de biomassa específicas para as diferentes tipologias florestais, de modo a refinar as estimativas de biomassa, além de possibilitar análises adequadas da distribuição espacial por tipologia.

A partir da análise comparativa de estoques de biomassa obtidos por meio de equações de biomassa, dados LiDAR e algoritmos de aprendizado de máquina, observou-se que a equação de d'Oliveira et al. (2012) apresentou valores de biomassa por hectare mais próximos de valores referência da literatura, quando comparada à

equação pantropical de Chave et al. (2014) e equações a partir de modelos de aprendizado de máquina. Com base nesse resultado, pode-se inferir que o uso de sistemas LiDAR tem elevado potencial não só para gerar mapas acurados da distribuição da biomassa, mas, também, para a obtenção de valores confiáveis de biomassa acima do solo por unidade de área no bioma Amazônia. Entretanto, também se observou que a obtenção de equações de biomassa a partir de modelos tradicionais (regressão linear) e de modelos de aprendizado de máquina constituem abordagens com bom desempenho preditivo da biomassa aérea de árvores no bioma Amazônia. Dessa forma, indica-se a integração de dados de sistemas LiDAR com dados de inventários florestais.

De maneira geral, os modelos de aprendizado de máquina tiveram desempenho preditivo muito similar quando comparados entre si, bem como quando comparados a um modelo de regressão linear. Dessa forma, conclui-se que a aplicação de modelos de aprendizado de máquina para prever valores de biomassa em florestas tropicais apresenta-se como uma alternativa aos modelos tradicionais.

6 CONSIDERAÇÕES FINAIS

Como considerações finais da presente pesquisa, ressalta-se que os resultados desta impactarão sobre múltiplas esferas do conhecimento científico, sendo as principais detalhadas na Figura 37:

FIGURA 36 - CONSIDERAÇÕES FINAIS DA TESE: IMPACTOS DA PESQUISA.

Impacto técnico científico <ul style="list-style-type: none"> - Modelos globais do clima; - Uso pelo IPCC, pesquisadores em geral; - Dados abertos. 	Inovação e difusão do conhecimento <ul style="list-style-type: none"> - Integração de dados de biomassa e carbono; - Iniciativa pioneira.
Impacto ambiental <ul style="list-style-type: none"> - Incorporação da base de dados em estudos de impactos climáticos; - Efeitos dos aumentos das emissões de carbono na dinâmica da floresta amazônica. 	Impacto socioeconômico <ul style="list-style-type: none"> - Implementação de políticas públicas para mitigação dos efeitos das mudanças climáticas.

FONTE: A AUTORA (2021).

1. Impacto técnico-científico

Estimativas precisas de biomassa em florestas tropicais, para posterior conversão em teores de carbono, são de suma importância nos estudos dos impactos frente a eventos climáticos extremos (ex. secas severas; tempestades com vento), para se saber como isso afetará a biodiversidade dos ecossistemas florestais ao redor do mundo, bem como a regulação do clima do planeta. Para tanto, o aperfeiçoamento dos modelos globais de clima e combinação de métodos empíricos de estimativas de biomassa e carbono, com rigor técnico-científico, são de fundamental importância.

Além disso, as informações disponibilizadas de maneira pública permitirão que qualquer pesquisador ou interessado do Brasil e do mundo possa ter acesso aos dados, com possibilidade de os utilizarem em suas pesquisas. Isso acarretará o aumento de estudos e pesquisas multidisciplinares sobre quantificação de carbono e biomassa na Amazônia e os impactos das mudanças climáticas sobre a sociedade, economia e meio-ambiente, o que contribuirá para os avanços científicos nacionais e

mundiais acerca dessa temática, seja por meio de relatórios técnicos, artigos científicos, teses e dissertações, cartilhas, guias, entre outros produtos.

Com relação aos dados abertos, segundo a definição da *Open Knowledge Internacional*, em suma, “dados são abertos quando qualquer pessoa pode livremente acessá-los, utilizá-los, modificá-los e compartilhá-los para qualquer finalidade, estando sujeito a, no máximo, a exigências que visem preservar sua proveniência e sua abertura”. Os principais impactos positivos da disponibilização de dados governamentais de maneira aberta são: aumento da transparência na gestão pública; contribuição da sociedade com serviços inovadores ao cidadão; aprimoramento na qualidade dos dados governamentais.

2. Inovação e difusão do conhecimento

A integração da base de dados do bioma Amazônia com o software JCarbon® é uma iniciativa pioneira acerca da disponibilização de estoques de biomassa e carbono a partir de grandes bases de dados de inventários florestais, com possibilidade de inserção de dados de inventários florestais que serão realizados no futuro.

O fato de a plataforma consistir em um ecossistema aberto permitirá que qualquer usuário do país e do mundo tenha acesso à base de dados, podendo utilizá-la em suas pesquisas. Dessa forma, a disponibilização de dados públicos de forma aberta culminará na difusão do conhecimento no que diz respeito à temática da quantificação de biomassa e carbono florestal na Amazônia brasileira.

3. Impacto ambiental

As informações integradas à plataforma digital também poderão ser utilizadas pelo IPCC (Painel Intergovernamental sobre Mudanças Climáticas) em seus relatórios científicos, possibilitando a incorporação da base de dados em estudos que investigam os possíveis impactos das Mudanças Climáticas na Floresta Amazônica e em estudos de modelagem climática com previsão de cenários futuros relacionados às mudanças no clima.

Dessa forma, poderão ser investigados os efeitos dos aumentos das emissões de carbono, seja por atividades antrópicas ou atividades naturais, na dinâmica da

floresta amazônica (flora, fauna e microclima), além dos possíveis impactos negativos sobre esse tão importante ecossistema.

4. Impacto socioeconômico

Além da quantificação do impacto causado pelo aumento das concentrações de CO₂ atmosférico, estimativas precisas de biomassa e carbono são fundamentais para a implementação de mecanismos e programas governamentais que visam à mitigação dos efeitos das mudanças climáticas. O conhecimento acerca desses impactos, expressados pela quantificação de biomassa e carbono, podem servir como uma valiosa informação para o poder público na investigação dos impactos econômicos das mudanças. Além disso, podem dar informações acerca das regiões mais vulneráveis e que necessitam de maiores investimentos com o intuito de mitigar os impactos sobre a economia local e, também, nacional.

Por fim, acredita-se que as pesquisas científicas buscam atender às demandas e lacunas existentes no meio científico por meio da complementação de um estudo anteriormente realizado ou por meio de feitos inéditos, resultando, por exemplo, em novos métodos, objetos de estudo e a expansão para áreas experimentais nunca antes estudadas. Nos últimos anos, tem-se mudado a mentalidade de que as pesquisas devem estar voltadas apenas para o meio acadêmico e científico.

Pesquisas financiadas com recursos provenientes de instituições financiadoras governamentais (ex. CNPq, CAPES), seja por meio de bolsas ou custeio de materiais de pesquisas, têm por obrigação prover conhecimentos que venham a contribuir com o desenvolvimento da sociedade, além de constituírem um importante pilar na melhoria do sistema educacional do país. Portanto, o presente trabalho também foi movido pelo desejo de que o meio científico esteja sempre próximo dos interesses e anseios da sociedade, visando sempre popularizar e disseminar os feitos das pesquisas em geral.

7 RECOMENDAÇÕES FUTURAS

As recomendações futuras do presente trabalho de tese foram sumarizadas na TABELA 26:

TABELA 26 – RECOMENDAÇÕES FUTURAS ALINHADAS COM OS OBJETIVOS DA TESE.

Objetivos da tese	Recomendações futuras
Consolidar uma plataforma digital de livre acesso que contenha informações acerca da quantificação dos estoques de carbono e biomassa no bioma Amazônia, a partir de dados de inventários florestais. (Objetivo Geral)	<ul style="list-style-type: none"> - Estabelecimento de novas plataformas na área florestal, com bases atualizadas de inventários florestais; - Inserção de novos dados de biomassa e carbono na plataforma do JCarbon®, tanto com dados do bioma Amazônia, como também dados dos demais biomas brasileiros.
Quantificar os estoques de biomassa e carbono acima do solo em todas as parcelas analisadas. (Objetivo Específico)	Estudos sobre a quantificação de carbono e biomassa florestal em grandes extensões territoriais, para todos os biomas brasileiros, em metodologia semelhante à realizada na presente pesquisa.
Integrar a base de dados ao software JCarbon®, com informações acerca das estimativas de biomassa e coordenadas geográficas de cada parcela. (Objetivo Específico)	Integração de dados de inventários florestais de grande extensão, como é o caso dos resultados oriundos do Inventário Florestal Nacional em plataformas <i>open data</i> (tais como plataforma BDiA e software JCarbon®), com quantificação de biomassa e carbono, a partir de metodologia semelhante à aplicada na presente pesquisa.

<p>Avaliar a aplicação de equações de biomassa específicas de floresta densa e floresta aberta para estimar biomassa e carbono em duas tipologias florestais, de ampla extensão territorial no bioma Amazônia.</p> <p>(Objetivo Específico)</p>	<p>Modelagem de equações específicas de biomassa e carbono para diferentes fitofisionomias no bioma Amazônia, bem como em outros biomas brasileiros, tanto para estudos mais regionais, quanto para estudos em maior escala (biomas, estados, municípios).</p>
<p>Comparar os efeitos das equações específicas de floresta densa e floresta aberta, com o intuito de propor nova uma abordagem de espacialização para gerar mapas de biomassa específicos para estas tipologias florestais.</p> <p>(Objetivo Específico)</p>	<p>Em mapas de biomassa e carbono, recomenda-se a inserção de informações acerca das diferentes fitofisionomias florestais. No caso específico desta pesquisa, apenas duas fitofisionomias foram exploradas (floresta densa e floresta aberta no bioma Amazônia). Entretanto, a exemplo do bioma Amazônia, as quantificações de biomassa e carbono nas demais fitofisionomias, de igual relevância ecológica – tais como campinas, campinaranas e florestas alagadas – podem ser consolidadas em mapas de biomassa e carbono.</p>
<p>Comparar estimativas de biomassa obtidas por meios de técnicas de regressão linear, aprendizado de máquina e dados LiDAR.</p> <p>(Objetivo Específico)</p>	<p>Difusão, cada vez maior, de estudos que utilizem outras técnicas aplicadas às estimativas de biomassa e carbono florestal, com destaque para técnicas de aprendizado de máquina. Apesar do crescente número de estudos nos últimos anos acerca desta temática, pode-se explorar a adequação de novas técnicas e ferramentas para</p>

quantificação de biomassa e carbono florestal. Além disso, recomenda-se a difusão de estudos que comparem estimativas obtidas por equações modeladas a partir de métricas LiDAR.

FONTE: A AUTORA (2021).

REFERÊNCIAS

- AGGARWAL, C. C. **Neural networks and deep learning**. New York: Springer, 2018.
- AHA, D. W.; KIBLER, D.; ALBERT, M. K. Instance-based learning algorithms. **Machine learning**, v. 6, n. 1, p. 37–66, 1991.
- ASNER, G. P. et al. Remote Sensing of Environment Quantifying forest canopy traits : Imaging spectroscopy versus field survey. **Remote Sensing of Environment**, v. 158, p. 15–27, 2015.
- AVITABILE, V. et al. An integrated pan-tropical biomass map using multiple reference datasets. **Global Change Biology**, v. 22, n. 4, p. 1406–1420, 2016.
- BACCINI, A. et al. Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. **Nature Climate Change**, v. 2, n. 3, p. 182–185, 2012.
- BARBOSA, R. I. et al. Allometric models to estimate tree height in northern amazonian ecotone forests. **Acta Amazonica**, v. 49, n. 2, p. 81–90, 2019.
- BARR, A.; FEIGENBAUM, E. A. **The Handbook of Artificial Intelligence**. Los Altos: William Kaufmann. Inc., 1981. p. 163–171.
- BAZEZEW, M. N.; HUSSIN, Y. A.; KLOOSTERMAN, E. H. Integrating Airborne LiDAR and Terrestrial Laser Scanner forest parameters for accurate above-ground biomass/carbon estimation in Ayer Hitam tropical forest, Malaysia. **International Journal of Applied Earth Observation and Geoinformation**, v. 73, p. 638–652, 2018.
- BEER, C. et al. Terrestrial gross carbon dioxide uptake: Global distribution and covariation with climate. **Science**, v. 329, n. 5993, p. 834–838, 2010.
- BELAND, M. et al. On promoting the use of lidar systems in forest ecosystem research. **Forest Ecology and Management**, v. 450, p. 117484, 2019.
- BEN-HUR, A.; WESTON, J. A user's guide to support vector machines. In: CARUGO O., EISENHABER F. (Eds). **Data mining techniques for the life sciences**. New York: Springer, 2010. p. 223–239.
- BERBERT, M. L. D. G. **Potencial do LiDAR terrestre como ferramenta para o manejo de florestas naturais**. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Florestal) - Instituto de Florestas, Universidade Federal Rural do Rio de Janeiro, Seropédica, 2016.
- BERNINGER, A. et al. SAR-based estimation of above-ground biomass and its changes in tropical forests of Kalimantan using L-and C-band. **Remote Sensing**, v. 10, n. 6, p. 831, 2018.

BERRY, M. J. A.; LINOFF, G. S. **Data mining techniques: for marketing, sales, and customer relationship management**. Indianapolis: Wiley Publishing, Inc., 2004.

BINOTI, M. L. M. DA S. et al. Redes neurais artificiais para estimar o volume de árvores no cerrado. **Árvore**, v. 38, n. 2, p. 283–288, 2014.

BLACKARD, J. A.; DEAN, D. J. Comparative accuracies of artificial neural networks and discriminant analysis in predicting forest cover types from cartographic variables. **Computers and Electronics in Agriculture**, v. 24, n. 3, p. 131–151, 1999.

BOOTH, B. B. B. et al. High sensitivity of future global warming to land carbon cycle processes. **Environmental Research Letters**, v. 7, p. 024002, n. 2, 2012.

BRASIL. Portal brasileiro de dados abertos. Disponível em: <http://dados.gov.br/>. Acesso em: 19 ago. 2020.

BRASIL. **Lei nº 12.527, de 18 de novembro de 2011**. Regula o acesso a informações previsto no inciso XXXIII do art. 5º, no inciso II do § 3º do art. 37 e no § 2º do art. 216 da Constituição Federal; altera a Lei nº 8.112, de 11 de dezembro de 1990; revoga a Lei nº 11.111, de 5 de maio de 2005, e dispositivos da Lei nº 8.159, de 8 de janeiro de 1991; e dá outras providências. Diário Oficial da União, Brasília, DF, 18 de novembro de 2011, p. 1, col. 1.

BRASIL. **Decreto nº 8.777, de 11 de maio de 2016**. Institui a Política de Dados Abertos do Poder Executivo federal. Diário Oficial da União, Brasília, DF, n. 90, 12 de maio de 2016, Seção 1, p. 21.

BREIDENBACH, J.; ASTRUP, R. Small area estimation of forest attributes in the Norwegian National Forest Inventory. **European Journal of Forest Research**, v. 131, n. 4, p. 1255–1267, 2012.

BREIMAN, L. et al. **Classification and Regression Trees**. Monterey: Wadsworth and Brooks, 1984.

BREIMAN, L. Bagging predictors. **Machine learning**, v. 24, n. 2, p. 123–140, 1996.

BREIMAN, L. **Using adaptive bagging to debias regressions**. Berkely: UCB, 1999. Relatório Técnico.

BREIMAN, L. Random forests. **Machine learning**, v. 45, n. 1, p. 5–32, 2001.

BRIENEN, R. J. W. et al. Long-term decline of the Amazon carbon sink. **Nature**, v. 519, n. 7543, p. 344–348, 2015.

BROWN, S. Estimating biomass and biomass change of tropical forests: a primer. **Food & Agriculture Organization**, v. 134, 1997.

BROWN, S.; GILLESPIE, A. J. R.; LUGO, A. E. Biomass estimation methods for tropical forests with applications to forest inventory data. **Forest Science**, v. 35, n. 4, p. 881–902, 1989.

BROWN, S.; LUGO, A. E. Aboveground biomass estimates for tropical moist forests of the Brazilian Amazon. **Interciencia**, v. 17, n. 1, p. 8-18, 1992.

BURGES, C. J. C. A tutorial on support vector machines for pattern recognition. **Data mining and knowledge discovery**, v. 2, n. 2, p. 121–167, 1998.

CASTILLO, M. E. et al. Evaluation of forest cover change using remote sensing techniques and landscape metrics in Moncayo Natural Park (Spain). **Applied Geography**, v. 62, p. 247–255, 2015.

CASTRO, V. O. R. et al. Individual Growth Model for Eucalyptus Stands in Brazil Using Artificial Neural Network. **ISRN Forestry**, v. 2013, p. 1–12, 2013.

CHAKRAVERTY, S.; SAHOO, D. M.; MAHATO, N. R. **Concepts of Soft Computing**. Singapore: Springer, 2019. p. 167–173.

CHAMBERS, J. Q., DOS SANTOS, J., RIBEIRO, R. J., AND HIGUCHI, N.: Tree damage, allometric relationships, and above-ground net primary production in central Amazon forest. **Forest Ecology and Management**, v. 152, p. 73–84, 2001.

CHANG, W. et al. **shiny: Web Application Framework for R.**, 2020. Disponível em: <https://cran.r-project.org/package=shiny>. Acesso em: 12 out. 2020.

CHAVE, J. et al. Improved allometric models to estimate the aboveground biomass of tropical trees. **Global change biology**, v. 20, n. 10, p. 3177–3190, 2014.

CHEN, L. et al. Estimation of forest above-ground biomass by geographically weighted regression and machine learning with Sentinel imagery. **Forests**, v. 9, n. 10, p. 582, 2018.

CLARK, D. A. Sources or sinks? The responses of tropical forests to current and future climate and atmospheric composition. **Philosophical Transactions of the Royal Society B: Biological Sciences**, v. 359, n. 1443, p. 477–491, 2004.

CRISTIANINI, N.; SHAW-TAYLOR, J. **An introduction to support vector machines and other kernel-based learning methods**. Cambridge: Cambridge University Press, 2000.

CTN-IFN/BR. **Projeto Inventário Florestal Nacional**. Disponível em: <http://www.florestal.gov.br/inventario-florestal-nacional>. Acesso em: 27 jul. 2020.

CUTLER, M. E. J. et al. Estimating tropical forest biomass with a combination of SAR image texture and Landsat TM data: An assessment of predictions between regions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 70, p. 66–77, 2012.

D'OLIVEIRA, M. V. N. et al. Estimating forest biomass and identifying low-intensity logging areas using airborne scanning lidar in Antimary State Forest, Acre State, Western Brazilian Amazon. **Remote Sensing of Environment**, v. 124, p. 479–491, 2012.

DA SILVA, K. E.; MATOS, F. D. D. A.; FERREIRA, M. M. Composição florística e fitossociologia de espécies arbóreas do Parque Fenológico da Embrapa Amazônia Ocidental. **Acta Amazonica**, v. 38, n. 2, p. 213–222, 2008.

DASSOT, M.; CONSTANT, T.; FOURNIER, M. The use of terrestrial LiDAR technology in forest science: application fields, benefits and challenges. **Annals of forest science**, v. 68, n. 5, p. 959–974, 2011.

DAVID, H. C., et al. Carbon stock classification for tropical forests in Brazil: understanding the effect of stand and climate variables. **Forest Ecology and Management**, v. 404, p. 241–250, 2017.

DE'ATH, G.; FABRICIUS, K. E. Classification and regression trees: a powerful yet simple technique for ecological data analysis. **Ecology**, v. 81, n. 11, p. 3178–3192, 2000.

DE ALMEIDA, C. T. et al. Combining LiDAR and hyperspectral data for aboveground biomass modeling in the Brazilian Amazon using different regression algorithms. **Remote Sensing of Environment**, v. 232, p. 111323, 2019.

DBpedia. Disponível em: <http://wiki.dbpedia.org/>. Acesso em: 23 set. 2020.

DEBASTIANI, A. B. et al. Evaluating SAR-optical sensor fusion for aboveground biomass estimation in a Brazilian tropical forest. **Annals of Forest Research**, v. 62, n. 2, p. 109–122, 2019.

EFRON, B. Bootstrap Methods: Another Look at the Jackknife. **Annals of Statistics**, v. 7, n. 1, p. 1–26, 1979.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). Projeto Paisagens Sustentáveis. Disponível em: <https://www.embrapa.br/busca-de-solucoes-tecnologicas/-/produto-servico/3862/paisagens-sustentaveis>. Acesso em: 19 set. 2019.

ESRI. **ArcGIS Desktop: versão 10.5**. Redlands, CA: Environmental Systems Research Institute, 2020.

EUROPE UNION. **Joinup**. Disponível em: <https://joinup.ec.europa.eu/>. Acesso em: 07 jun. 2020.

EUROPE UNION DATA. Disponível em: <http://open-data.europa.eu/en/data>. Acesso em: 23 out. 2020.

FACELI, K. et al. **Inteligência artificial: uma abordagem de aprendizado de máquina**. Rio de Janeiro: LTC, 2011.

FAN, S. et al. A large terrestrial carbon sink in North America implied by atmospheric and oceanic carbon dioxide data and models. **Science**, v. 282, n. 5388, p. 442–446, 1998.

FAO. **Global Forest Resources Assessment (FRA) - Brazil. Report 2020.** Disponível em: <http://www.fao.org/3/ca9976en/ca9976en.pdf>. Acesso em: 29 jul. 2020.

FATH, A. H.; MADANIFAR, F.; ABBASI, M. Implementation of multilayer perceptron (MLP) and radial basis function (RBF) neural networks to predict solution gas-oil ratio of crude oil systems. **Petroleum**, v. 6, n. 1, p. 80–91, 2018.

FAYYAD, U.; PIATETSKY-SHAPIO, G.; SMYTH, P. From Data Mining to Knowledge Discovery in Databases. **AI Magazine**, v. 17, n. 3, p. 37–54, 1996.

FEARNSIDE, P. M. Greenhouse gases from deforestation in Brazilian Amazonia: net committed emissions. **Climatic Change**, v. 35, n. 3, p. 321–360, 1997a.

FEARNSIDE, P. M. Wood density for estimating forest biomass in Brazilian Amazonia. **Forest ecology and management**, v. 90, n. 1, p. 59–87, 1997b.

FEARNSIDE, P. M.; LEAL, N.; FERNANDES, F. M. Rainforest burning and the global carbon budget: biomass, combustion efficiency, and charcoal formation in the Brazilian Amazon. **Journal of Geophysical Research**, v. 98, n. D9, p. 16733–16743, 1993.

FELDPUSCH, T. R. et al. Height-diameter allometry of tropical forest trees. **Biogeosciences**, v. 8, n. 5, p. 1081–1106, 2011.

FELDPUSCH, T. R. et al. Tree height integrated into pantropical forest biomass estimates. **Biogeosciences**, v. 9, n. 8, p. 3381–3403, 2012.

FENG, Y. et al. Examining effective use of data sources and modeling algorithms for improving biomass estimation in a moist tropical forest of the Brazilian Amazon. **International Journal of Digital Earth**, v. 10, n. 10, p. 996–1016, 2017.

FIORENTIN, L. D. et al. Quantificação e modelagem da biomassa e carbono da regeneração natural em área de Floresta Ombrófila Mista. **Revista Brasileira de Biometria**, v. 33, n. 2, p. 251–267, 2015.

FOX, J.; WEISBERG, S. **Companion to Applied Regression**, 2 ed., 2011. Disponível em: <http://socserv.socsci.mcmaster.ca/jfox/Books/Companion>. Acesso em: 23 mar. 2020.

FRIEND, A. D. et al. Carbon residence time dominates uncertainty in terrestrial vegetation responses to future climate and atmospheric CO₂. **Proceedings of the National Academy of Sciences of the United States of America**, v. 111, n. 9, p. 3280–3285, 2014.

GEDI, GEDI ECOSYSTEM LIDAR. Disponível em: <https://gedi.umd.edu/mission/mission-overview>. Acesso em: 29 ago. 2020.

GEETHA, R.; BHANU, S. R. D. Recruitment through artificial intelligence: a conceptual study. **International Journal of Mechanical Engineering and Technology**, v. 9, n. 7, p. 63–70, 2018.

GEVREY, M.; DIMOPOULOS, I.; LEK, S. Review and comparison of methods to study the contribution of variables in artificial neural network models. **Ecological modelling**, v. 160, n. 3, p. 249–264, 2003.

GIL-TENA, A. et al. Modelling bird species richness with neural networks for forest. **Forest Systems**, v. 3, n. 4, p. 113, 2011.

GOOGLE TRENDS. Disponível em: <https://www.google.com/trends>. Acesso em: 16 out. 2020.

GOOGLE FINANCE. Disponível em: <https://www.google.com/trends>. Acesso em: 29 out. 2020.

GOVERNMENT OF CANADA DATA. Disponível em: <http://open.canada.ca>. Acesso em: 23 out. 2020.

HASENAUER, H.; MERKL, D.; WEINGARTNER, M. Estimating tree mortality of Norway spruce stands with neural networks. **Advances in Environmental Research**, v. 5, n. 4, p. 405–414, 2001.

HAYKIN, S. **Redes neurais: princípios e prática**. São Paulo: Bookman Editora, 2007.

HEALTH DATA. Disponível em: <http://www.healthdata.gov>. Acesso em: 16 out. 2020.

HERNÁNDEZ-STEFANONI, J. L. et al. Improving aboveground biomass maps of tropical dry forests by integrating LiDAR, ALOS PALSAR, climate and field data. **Carbon balance and management**, v. 15, n. 1, p. 1–17, 2020.

HETHCOAT, M. G. et al. A machine learning approach to map tropical selective logging. **Remote Sensing of Environment**, v. 221, p. 569–582, fev. 2019.

HIGUCHI, N. et al. Biomassa da parte aérea da vegetação da floresta tropical úmida de terra-firme da Amazônia brasileira. **Acta Amazonica**, v. 28, n. 2, p. 153–166, 1998.

HIGUCHI, N. et al. Dinâmica E Balanço Do Carbono Da Vegetação Primária Da Amazônia Central. **Floresta**, v. 34, n. 3, p. 295–304, 2004.

HIGUCHI, N. et al. A floresta Amazônica e a água da chuva. **Floresta**, v. 41, n. 3, p. 427–434, 2011.

HIGUCHI, N.; CARVALHO JR, J. Biomassa florestal e conteúdo de carbono de espécies arbóreas da Amazônia. In: **Emissão x Seqüestro de CO₂ - Uma Nova Oportunidade de Negócios para o Brasil**. [s.l.] CVRD, 1995. p. 125–153.

HOPKINS, M. J. G. Modelling the known and unknown plant biodiversity of the Amazon Basin. **Journal of Biogeography**, v. 34, n. 8, p. 1400–1411, 2007.

HUDAK, A. T. et al. Quantifying aboveground forest carbon pools and fluxes from repeat LiDAR surveys. **Remote Sensing of Environment**, v. 123, p. 25–40, 2012.

HUNTINGFORD, C. et al. Simulated resilience of tropical rainforests to CO₂-induced climate change. **Nature Geoscience**, v. 6, n. 4, p. 268–273, 2013.

HYYPÄÄ, J. et al. Remote sensing of forests from Lidar and Radar. In: THENKABAIL, P. S. (Ed.). **Land Resources Monitoring, Modeling, and Mapping with Remote Sensing**. Boca Raton: CRC Press, 2015. p. 397–427.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Banco de Dados de Informações Ambientais (BDiA)**. Disponível em: <https://bdiaweb.ibge.gov.br/#/home>. Acesso em: 06 fev. 2020.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Infraestrutura Nacional de Dados Espaciais (INDE)**. Disponível em: <<https://inde.gov.br/>>. Acesso em: 12 fev. 2020.

IMADA, A. A Literature Review : Forest Management with Neural Network and Artificial Intelligence. In: GOLOVKO V.; IMADA A. (Eds.). **Neural Networks and Artificial Intelligence**. New York: Springer, 2014. vol 440. n. 1999, p. 9–21.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). **2006 IPCC guidelines for national greenhouse gas inventories**. Disponível em: <https://www.ipcc-nggip.iges.or.jp/public/2006gl/>. Acesso em: 19 set. 2020.

INSTITUTO DE PESQUISA ECONÔMICA APLICADA (IPEA). Dados abertos do IPEADATA. Disponível em: <http://www.ipeadata.gov.br>. Acesso em: 21 out. 2020.

KOETZ, B. et al. Fusion of imaging spectrometer LIDAR data using support vector machines for land cover classification. In: **ISPRS Working Group VII/1 Workshop ISPRS'07: "Physical Measurements and Signatures in Remote Sensing"**, 2007, Davos.

KUHN, M.; JOHNSON, K. **Applied predictive modeling**. New York: Springer, 2013. v. 26.

KUHN, M. et al. caret: Classification and Regression Training. R package version 6.0-82. 2019. Disponível em: <https://CRAN.R-project.org/package=caret>. Acesso em: 02 abr. 2020.

LEFSKY, M. A. et al. Lidar remote sensing of the canopy structure and biophysical properties of Douglas-fir western hemlock forests. **Remote sensing of environment**, v. 70, n. 3, p. 339–361, 1999.

LEFSKY, M. A. et al. Lidar remote sensing for ecosystem studies: Lidar, an emerging remote sensing technology that directly measures the three-dimensional distribution of plant canopies, can accurately estimate vegetation structural attributes and should be of particular inte. **BioScience**, v. 52, n. 1, p. 19–30, 2002.

LIAW, A.; WIENER, M. Classification and regression by randomForest. **R news**, v. 2, n. 3, p. 18–22, 2002.

LIU, R. et al. Uncertainty analysis of total phosphorus spatial-temporal variations in the Yangtze River Estuary using different interpolation methods. **Marine Pollution Bulletin**, v. 86, n. 1–2, p. 68–75, 2014.

LONGO, M. et al. Aboveground biomass variability across intact and degraded forests in the Brazilian Amazon. **Global Biogeochemical Cycles**, v. 30, n. 11, p. 1639–1660, 2016.

LU, D. et al. Mapping and monitoring land degradation risks in the Western Brazilian Amazon using multitemporal Landsat TM/ETM+ images. **Land Degradation & Development**, v. 18, n. 1, p. 41–54, 2007.

MACHADO, S. A.; FIGUEIREDO FILHO, A. **Dendrometria**. Curitiba: Ed. dos Autores, 2013.

MALHI, Y. et al. The regional variation of aboveground live biomass in old-growth Amazonian forests. **Global Change Biology**, v. 12, n. 7, p. 1107–1138, 2006.

MALTAMO, M. et al. Identifying and quantifying structural characteristics of heterogeneous boreal forests using laser scanner data. **Forest ecology and management**, v. 216, n. 1–3, p. 41–50, 2005.

MARTINELLI, L. A.; MOREIRA, M. Z.; BROWN, I. F. **Incertezas associadas às estimativas de biomassa em florestas tropicais: o exemplo de uma floresta situada no estado de Rondônia**. In: SEMINÁRIO EMISSÃO X SEQÜESTRO DE CO₂: uma oportunidade de negócios para o Brasil, 1994, Rio de Janeiro. Anais... Rio de Janeiro: Companhia Vale do Rio Doce, 1994. p.197-221.

MASCARO, J. et al. A tale of two “forests”: Random Forest machine learning aids tropical Forest carbon mapping. **PLoS ONE**, v. 9, n. 1, p. 12–16, 2014.

MAZZEI, L. et al. Above-ground biomass dynamics after reduced-impact logging in the Eastern Amazon. **Forest ecology and management**, v. 259, n. 3, p. 367–373, 2010.

MCCORDUCK, P. **Machines Who Think: A Personal Inquiry into the History and Prospects of artificial intelligence**. Boca Raton: CRC Press, 1979.

MCGAUGHEY, R. J. M. FUSION/LDV: software for LiDAR data analysis and visualization (version 3.60). Seattle, WA. 2016. Disponível em: http://forsys.cfr.washington.edu/fusion/FUSION_manual.pdf.

MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO (MCTI). **Terceiro Inventário Brasileiro de Emissões e Remoções Antrópicas de Gases de Efeito Estufa** - Emissões no Setor Uso da Terra, Mudança do Uso da Terra e Florestas. 2015. Disponível em: http://redd.mma.gov.br/images/FREL/RR_LULUCF_Mudanca-de-Uso-e-Floresta.pdf. Acesso em: 22 jul. 2020.

MONTAÑO, R. A. N. R. **Aplicação de técnicas de aprendizado de máquina na mensuração florestal**. 2016. 102 f. Tese (Doutorado em Engenharia Florestal) - Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba, 2016.

MONTAÑO, R. A. N. R. et al. Artificial Intelligence Models to Estimate Biomass of Tropical Forest Trees. **Polibits**, v. 56, n. 1, p. 29–37, 2017.

MORGAN, J. N.; SONQUIST, J. A. Problems in the analysis of survey data, and a proposal. **Journal of the American statistical association**, v. 58, n. 302, p. 415–434, 1963.

NAESSET, E. Estimating timber volume of forest stands using airborne laser scanner data. **Remote Sensing of Environment**, v. 61, n. 2, p. 246–253, 1997.

NASA DATA. Disponível em: <https://data.nasa.gov>. Acesso em: 27 set. 2020.

NGEE-TROPICS. **Next-Generation Ecosystem Experiments** –Tropics. Disponível em: <https://ngee-tropics.lbl.gov/>. Acesso em: 28 jun. 2020.

NIE, S. et al. Above-ground biomass estimation using airborne discrete-return and full-waveform LiDAR data in a coniferous forest. **Ecological Indicators**, v. 78, p. 221–228, 2017.

NINGTHOUJAM, R. K.; JOSHI, P. K.; ROY, P. S. Retrieval of forest biomass for tropical deciduous mixed forest using ALOS PALSAR mosaic imagery and field plot data. **International journal of applied earth observation and geoinformation**, v. 69, p. 206–216, 2018.

NOBLE, W. S. What is a support vector machine? **Nature Biotechnology**, v. 24, n. 12, p. 1565–1567, 2006.

NOBRE, C. A. Amazônia: fonte ou sumidouro de carbono? In: **Causas e dinâmica do desmatamento na Amazônia**. São José dos Campos: [s.n.]. p. 197–224.

NOGUEIRA, E. M. et al. Wood density in forests of Brazil's "arc of deforestation": Implications for biomass and flux of carbon from land-use change in Amazonia. **Forest Ecology and Management**, v. 248, n. 3, p. 119–135, 2007.

NOGUEIRA, E. M. et al. Estimates of forest biomass in the Brazilian Amazon: new allometric equations and adjustments to biomass from wood-volume inventories. **Forest Ecology and Management**, v. 256, n. 11, p. 1853–1867, 2008.

NOGUEIRA, E. M.; NELSON, B. W.; FEARNSIDE, P. M. Wood density in dense forest in central Amazonia, Brazil. **Forest Ecology and Management**, v. 208, n. 1–3, p. 261–286, 2005.

OMETTO, J. P. et al. Amazon forest biomass density maps: Tackling the uncertainty in carbon emission estimates. **Climatic Change**, v. 124, n. 3, p. 545–560, 2014.

OPEN DATA MONITOR. Disponível em: <http://opendatamonitor.eu>. Acesso em: 01 out. 2020.

OPEN DATA NETWORK. Disponível em: <http://www.opendatanetwork.com>. Acesso em: 17 set. 2020.

OPEN KNOWLEDGE BRASIL. Disponível em: <https://br.okfn.org/>. Acesso em: 12 fev. 2020a.

OPEN KNOWLEDGE FOUNDATION. Disponível em: <https://okfn.org/about/>. Acesso em: 12 fev. 2020b.

ORACLE. Disponível em: <http://www.oracle.com/index.html>. Acesso em: 19 mai. 2020.

PAN, Y. et al. A large and persistent carbon sink in the world's forests. **Science**, v. 333, n. August, p. 988–993, 2011.

PHAM, B. T. et al. A hybrid machine learning ensemble approach based on a Radial Basis Function neural network and Rotation Forest for landslide susceptibility modeling: A case study in the Himalayan area, India. **International Journal of Sediment Research**, v. 33, n. 2, p. 157–170, 2018.

PHILLIPS, O. L. et al. Changes in the carbon balance of tropical forests: Evidence from long-term plots. **Science**, v. 282, n. 5388, p. 439–442, 1998.

PHILLIPS, O. L. et al. Drought sensitivity of the amazon rainforest. **Science**, v. 323, n. 5919, p. 1344–1347, 2009.

PUT, R. et al. Classification and regression tree analysis for molecular descriptor selection and retention prediction in chromatographic quantitative structure–retention relationship studies. **Journal of Chromatography A**, v. 988, n. 2, p. 261–276, 2003.

QUANDL. Disponível em: <https://www.quandl.com>. Acesso em: 16 out. 2020.

R CORE TEAM. **R: a language and environment for statistical computing, version 3.0. 2**. Disponível em: <https://www.r-project.org/>. Acesso em: 18 out. 2019.

RAHMAN, H. S.; ALIREZA, K.; REZA, G. Application of Artificial Neural Network, Kriging, and Inverse Distance Weighting Models for Estimation of Scour Depth around Bridge Pier with Bed Sill. **Journal of Software Engineering and Applications**, v. 03, n. 10, p. 944–964, 2010.

RATUCHNE, L. C. et al. Estado da Arte na Quantificação de Biomassa em Raízes de Formações Florestais State-of-the-art in the Quantification of Biomass in Roots of Forest Formations. **Floresta e Ambiente**, v. 23, n. 3, p. 450–462, 2016.

REX, F. E. **Estimativas do estoque e dinâmica de biomassa acima do solo utilizando diferentes abordagens estatísticas e dados LiDAR em floresta tropical**. 2019. 121 f. Dissertação (Mestrado em Engenharia Florestal) - Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba, 2019.

REX, F. E. et al. Estimating above-ground biomass of *araucaria angustifolia* (Bertol.) Kuntze using LiDAR Data. **Floresta e Ambiente**, v. 26, n. 4, 2019.

REX, F. E. et al. Dynamics of Above-Ground Biomass in the Brazilian Amazon Using LiDAR Data. **Anuário do Instituto de Geociências - UFRJ**, v. 43, p. 228–238, 2020.

RIBEIRO, J. E. L. DA S et al. **Flora da reserva Ducke**. Manaus: INPA, 1999

RUSSELL, S.; NORVIG, P. Artificial Intelligence: a modern approach. **Prentice-Hall, Egnlewood Cliffs**, v. 25, n. 27, p. 79–80, 1995.

SAATCHI, S. S. et al. Benchmark map of forest carbon stocks in tropical regions across three continents. **Proceedings of the National Academy of Sciences of the United States of America**, v. 108, n. 24, p. 9899–9904, 2011.

SAKR, G. E. et al. Artificial intelligence for forest fire prediction. **IEEE/ASME International Conference on Advanced Intelligent Mechatronics, AIM**, p. 1311–1316, 2010.

SANQUETTA, C. R. Métodos de determinação de biomassa florestal. In: SANQUETTA, C. R. et al. (Eds.). **As florestas e o carbono**. Curitiba: [s.n.]. p. 119–140.

SANQUETTA, C. R. et al. On the use of data mining for estimating carbon storage in the trees. **Carbon Balance and Management**, v. 8, n. 1, p. 1–9, 2013.

SANQUETTA, C. R. et al. Comparison of data mining and allometric model in estimation of tree biomass. **BMC Bioinformatics**, v. 16, n. 1, p. 1–9, 2015.

SANQUETTA, C. R.; BALBINOT, R. Metodologias para a determinação de biomassa florestal. In: SANQUETTA, C. R. (Ed.). **Fixação de Carbono – atualidades, projetos e pesquisas**. Curitiba: UFPR, 2004. p. 77–93.

SCHAPIRE, R. E. et al. Boosting the margin: A new explanation for the effectiveness of voting methods. **The annals of statistics**, v. 26, n. 5, p. 1651–1686, 1998.

SCHIKOWSKI, A. B. et al. Modeling of stem form and volume through machine learning. **Anais da Academia Brasileira de Ciencias**, v. 90, n. 4, p. 3389–3401, 2018.

SILVA, R. P. **Alometria, estoque e dinâmica da biomassa de florestas primárias e secundárias na região de Manaus (AM)**. 2007. 152 f. Tese (Doutorado em Biologia Tropical e Recursos Naturais). Instituto Nacional de Pesquisas da Amazônia/Universidade Federal do Amazonas, Manaus, 2007.

SILVEIRA, P. et al. O Estado Da Arte Na Estimativa De Biomassa E Carbono Em Formações Florestais. **Floresta**, v. 38, n. 1, p. 185–206, 2008.

SIMONSON, W. et al. Modelling above-ground carbon dynamics using multi-temporal airborne lidar: insights from a Mediterranean woodland. **Biogeosciences**, v. 13, p. 961–973, 2016.

SKAPURA, D. M. **Building neural networks**. New York: ACM Press, 1996.

SLIK, J. W. F. et al. Large trees drive forest aboveground biomass variation in moist lowland forests across the tropics. **Global Ecology and Biogeography**, v. 22, n. 12, p. 1261–1271, 2013.

SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. **Statistics and computing**, v. 14, n. 3, p. 199–222, 2004.

SOTHE, C. et al. Evaluating Sentinel-2 and Landsat-8 data to map sucessional forest stages in a subtropical forest in Southern Brazil. **Remote Sensing**, v. 9, n. 8, p. 838, 2017.

SOUZA, D. V. et al. **Introdução ao R: aplicações florestais**. Curitiba: Ed. do autor, 2018.

SOUZA, D. V. et al. k-Nearest Neighbor Regression in the Estimation of Tectona Grandis Trunk Volume in the State of Pará, Brazil. **Journal of Sustainable Forestry**, v. 38, n. 8, p. 755–768, 2019.

SOUZA, D. V. **Aprendizado de máquina para predição de biomassa e volume comercial de árvores em florestas tropicais**. 2020. 171 f. Tese (Doutorado em Engenharia Florestal) - Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba, 2020.

STĘPIEŃ, B. Bootstrap confidence intervals for noise indicators. **Acta Acustica united with Acustica**, v. 102, n. 2, p. 389–397, 2016.

SWINGLER, K. **Applying neural networks: a practical guide**. San Francisco: Morgan Kaufmann, 1996.

TAIZ, L.; ZEIGER, E. **Fisiologia Vegetal**. 3. ed. ed. Porto Alegre: Artmed, 2004.

TAN, P. N.; STEINBACH, M.; KUMAR, V. **Introduction to Data Mining**. [s.l.] Ciência Moderna, 2009.

TEJADA, G. et al. Evaluating spatial coverage of data on the aboveground biomass in undisturbed forests in the Brazilian Amazon. **Carbon Balance and Management**, v. 14, n. 1, p.11, 2019.

TURING, A. M. Computing Machinery and Intelligence. **Creative Computing**, v. 6, n. 1, p. 44–53, 1950.

U.K. GOVERNMENT, O. D. **UK Government's open data**. Disponível em: <https://data.gov.uk/support>. Acesso em: 12 fev. 2020.

U.S. GOVERNMENT. **U.S. Government's open data**. Disponível em: <https://www.data.gov/>. Acesso em: 12 fev. 2020.

VAPNIK, V. **Estimation of Dependences Based on Empirical Data**. New York: Springer, 1982.

VAPNIK, V. **The nature of statistical learning theory**. 2nd. ed. New York: Springer-Verlag, 1995.

VAPNIK, V.; CHERVONENKIS, A. On the uniform convergence of relative frequencies

of events to their probabilities. **Theory of Probability and its Applications**, v. 16, n. 2, p. 264–280, 1971.

VASCONCELLOS, B. N. **Estimativa de variáveis dendrométricas individuais de *Araucaria angustifolia* (Bertol.) Kuntze** por meio de dados laser scanner aéreo e terrestre. 2020. 166 f. Tese (Doutorado em Engenharia Florestal) - Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba, 2020. Submetido à publicação.

VASILAKOS, C. et al. Identifying wildland fire ignition factors through sensitivity analysis of a neural network. **Natural Hazards**, v. 50, n. 1, p. 125–143, 2009.

VENABLES, W. N.; RIPLEY, B. D. **Modern Applied Statistics with S**. 4 ed. New York: Springer, 2002.

VENTUROLI, F.; SANQUETTA, C. R. Alometria e biomassa em uma Savana Parque do Brasil Biomass and allometric relations in a Brazilian Savanna-Park. **Scientia Forestalis**, v. 47, n. 124, p. 708-713, 2019.

VINE, E.; SATHAYE, J. **The monitoring, evaluation, reporting, and verification of climate change mitigation projects: Discussion of issues and methodologies and review of existing protocols and guidelines**. Berkeley: Lawrence Berkeley National Lab, 1997. Relatório Técnico.

WATZLAWICK, L. F.; KIRCHNER, F. F.; SANQUETTA, C. R. Estimativa de biomassa e carbono em floresta com araucaria utilizando imagens do satélite Ikonos II. **Ciência Florestal**, v. 19, n. 2, p. 169–181, 2009.

WEST, P. W.; WEST, P. W. **Tree and forest measurement**. New York: Springer, 2009.

WHITE, J. C. et al. Remote sensing technologies for enhancing forest inventories: A review. **Canadian Journal of Remote Sensing**, v. 42, n. 5, p. 619–641, 2016.

WICKHAM, H. **ggplot2: elegant graphics for data analysis**. New York: Springer, 2016.

WICKHAM H.; HENRY, L. Tidy: **Easily Tidy Data with 'spread()' and 'gather()' Functions**. R package version 0.8.3. 2019a. Disponível em: <https://CRAN.R-project.org/package=tidy>. Acesso em: 29 set. 2020.

WICKHAM, H. et al. Dplyr: **A Grammar of Data Manipulation**. R package version 0.8.0.1. 2019b. Disponível em: <https://CRAN.R-project.org/package=dplyr>. Acesso em: 23 set. 2020.

WILKINSON, L. Classification and regression trees. **Systat**, v. 11, p. 35–56, 2004.

WITTKKE, S. et al. Comparison of two-dimensional multitemporal Sentinel-2 data with three-dimensional remote sensing data sources for forest inventory parameter estimation over a boreal forest. **International Journal of Applied Earth Observation and Geoinformation**, v. 76, p. 167–178, 2019.

WOJCIECHOWSKI, J. J. **Carbon - software na web com data mining para estimativas**

de volume, biomassa e carbono em florestas. 2015. 172 f. Tese (Doutorado em Engenharia Florestal) - Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba, 2015.

WORLD BANK DATA. Disponível em: <http://data.worldbank.org>. Acesso em: 27 set. 2020.

XIE, Y. knitr: **A General-Purpose Package for Dynamic Report Generation in R**. R package version 1.22. 2019. Disponível em: <https://cran.r-project.org/web/packages/knitr/index.html>. Acesso em: 19 ago. 2020.

YASREBI, J. et al. Evaluation and comparison of ordinary kriging and inverse distance weighting methods for prediction of spatial variability of some chemical parameters. **Research Journal of Biological Sciences**, v. 4, n. 1, p. 93–102, 2009.

ZHENG, G. et al. Combining remote sensing imagery and forest age inventory for biomass mapping. **Journal of Environmental Management**, v. 85, n. 3, p. 616–623, 2007.

ZIMMERMAN, D. et al. An experimental comparison of ordinary and universal kriging and inverse distance weighting. **Mathematical Geology**, v. 31, n. 4, p. 375–390, 1999.

**APÊNDICE 1 – DENSIDADE DA MADEIRA POR ESPÉCIE, APLICADA AO
CONJUNTO DE DADOS DA SEÇÃO 4.4.**

Família	Espécie	Densidade (g cm⁻³)
Anacardiaceae	<i>Anacardium spruceanum</i>	0,46
Anacardiaceae	<i>Astronium graveolens</i>	0,85
Anacardiaceae	<i>Spondias</i> sp.	0,38
Anacardiaceae	<i>Tapirira guianensis</i>	0,45
Anacardiaceae	<i>Thyrsodium spruceanum</i>	0,64
Annonaceae	<i>Annona ambotay</i>	0,61
Annonaceae	<i>Annona</i> sp.	0,5
Annonaceae	<i>Duguetia surinamensis</i>	0,8
Annonaceae	<i>Guatteria schomburgkiana</i>	0,6
Annonaceae	<i>Xylopia nitida</i>	0,55
Annonaceae	<i>Xylopia</i> sp.	0,61
Apocynaceae	<i>Ambelania acida</i>	0,55
Apocynaceae	<i>Aspidosperma excelsum</i>	0,79
Apocynaceae	<i>Aspidosperma parvifolium</i>	0,78
Apocynaceae	<i>Aspidosperma spruceanum</i>	0,74
Apocynaceae	<i>Himatanthus attenuatus</i>	0,48
Araliaceae	<i>Schefflera morototoni</i>	0,44
Bignoniaceae	<i>Handroanthus impetiginosus</i>	0,92
Bignoniaceae	<i>Jacaranda copaia</i>	0,35
Boraginaceae	<i>Cordia goeldiana</i>	0,49
Boraginaceae	<i>Cordia scabrifolia</i>	0,47
Burseraceae	<i>Protium hebetatum</i>	0,62
Burseraceae	<i>Protium paniculatum</i>	0,49
Burseraceae	<i>Tetragastris altissima</i>	0,71
Burseraceae	<i>Tetragastris panamensis</i>	0,72
Burseraceae	<i>Tetragastris</i> sp.	0,71
Burseraceae	<i>Trattinnickia burserifolia</i>	0,46
Calophyllaceae	<i>Caraipa grandifolia</i>	0,64
Caryocaraceae	<i>Caryocar glabrum</i>	0,71
Caryocaraceae	<i>Caryocar villosum</i>	0,78
Chrysobalanaceae	<i>Couepia robusta</i>	0,64
Chrysobalanaceae	<i>Licania canescens</i>	0,88
Chrysobalanaceae	<i>Licania guianensis</i>	0,77

Chrysobalanaceae	<i>Licania heteromorpha</i>	0,82
Clusiaceae	<i>Symphonia globulifera</i>	0,6
Clusiaceae	<i>Tovomita</i> sp.	0,7
Combretaceae	<i>Terminalia amazonia</i>	0,68
Ebenaceae	<i>Diospyros guianensis</i>	0,73
Elaeocarpaceae	<i>Sloanea guianensis</i>	0,82
Euphorbiaceae	<i>Glycydendron amazonicum</i>	0,67
Euphorbiaceae	<i>Hevea brasiliensis</i>	0,49
Euphorbiaceae	<i>Micrandra minor</i>	0,58
Euphorbiaceae	<i>Sagotia racemosa</i>	0,58
Fabaceae	<i>Abarema cochleata</i>	0,64
Fabaceae	<i>Abarema jupunba</i>	0,61
Fabaceae	<i>Bowdichia nitida</i>	0,81
Fabaceae	<i>Chamaecrista xinguensis</i>	0,64
Fabaceae	<i>Copaifera reticulata</i>	0,61
Fabaceae	<i>Dialium guianense</i>	0,89
Fabaceae	<i>Dimorphandra macrostachya</i>	0,7
Fabaceae	<i>Dinizia excelsa</i>	0,9
Fabaceae	<i>Diploptropis</i> sp.	0,71
Fabaceae	<i>Enterolobium schomburgkii</i>	0,72
Fabaceae	<i>Eperua bijuga</i>	0,73
Fabaceae	<i>Hymenaea courbaril</i>	0,77
Fabaceae	<i>Hymenaea parvifolia</i>	0,88
Fabaceae	<i>Hymenolobium heterocarpum</i>	0,64
Fabaceae	<i>Hymenolobium modestum</i>	0,66
Fabaceae	<i>Inga alba</i>	0,59
Fabaceae	<i>Inga grandis</i>	0,58
Fabaceae	<i>Inga heterophylla</i>	0,56
Fabaceae	<i>Inga marginata</i>	0,58
Fabaceae	<i>Inga nobilis</i>	0,56
Fabaceae	<i>Inga</i> sp.	0,57
Fabaceae	<i>Inga thibaudiana</i>	0,58
Fabaceae	<i>Myrocarpus frondosus</i>	0,8
Fabaceae	<i>Myroxylon peruiferum</i>	0,83
Fabaceae	<i>Ormosia coccinea</i>	0,63

Fabaceae	<i>Ormosia flava</i>	0,58
Fabaceae	<i>Ormosia grossa</i>	0,68
Fabaceae	<i>Ormosia nobilis</i>	0,58
Fabaceae	<i>Parkia gigantocarpa</i>	0,52
Fabaceae	<i>Parkia nitida</i>	0,38
Fabaceae	<i>Parkia</i> sp.	0,52
Fabaceae	<i>Peltogyne lecointei</i>	0,76
Fabaceae	<i>Poeppigia procera</i>	0,73
Fabaceae	<i>Pseudopiptadenia suaveolens</i>	0,68
Fabaceae	<i>Pterocarpus</i> sp.	0,47
Fabaceae	<i>Stryphnodendron paniculatum</i>	0,66
Fabaceae	<i>Stryphnodendron pulcherrimum</i>	0,47
Fabaceae	<i>Swartzia corrugata</i>	1,06
Fabaceae	<i>Swartzia</i> sp.	0,86
Fabaceae	<i>Tachigali myrmecophila</i>	0,53
Fabaceae	<i>Tachigali paniculata</i>	0,56
Fabaceae	<i>Vatairea guianensis</i>	0,68
Fabaceae	<i>Vataireopsis speciosa</i>	0,66
Fabaceae	<i>Zollernia paraensis</i>	1
Fabaceae	<i>Zygia racemosa</i>	0,75
Goupiaceae	<i>Goupia glabra</i>	0,72
Humiriaceae	<i>Endopleura uchi</i>	0,79
Humiriaceae	<i>Sacoglottis guianensis</i>	0,84
Hypericaceae	<i>Vismia floribunda</i>	0,64
Lauraceae	<i>Aiouea</i> sp.	0,37
Lauraceae	<i>Aniba canelilla</i>	0,94
Lauraceae	<i>Aniba parviflora</i>	0,54
Lauraceae	<i>Endlicheria</i> sp.	0,49
Lauraceae	<i>Licaria</i> sp.	0,82
Lauraceae	<i>Mezilaurus itauba</i>	0,74
Lauraceae	<i>Nectandra cuspidata</i>	0,56
Lauraceae	<i>Ocotea canaliculata</i>	0,46
Lauraceae	<i>Ocotea cernua</i>	0,45
Lauraceae	<i>Ocotea glomerata</i>	0,51
Lauraceae	<i>Sextonia rubra</i>	0,55

Lecythidaceae	<i>Couratari stellata</i>	0,63
Lecythidaceae	<i>Eschweilera amazonica</i>	0,9
Lecythidaceae	<i>Eschweilera coriacea</i>	0,84
Lecythidaceae	<i>Eschweilera micrantha</i>	0,86
Lecythidaceae	<i>Eschweilera ovata</i>	0,9
Lecythidaceae	<i>Eschweilera parviflora</i>	0,86
Lecythidaceae	<i>Eschweilera</i> sp.	0,84
Lecythidaceae	<i>Lecythis idatimon</i>	0,79
Lecythidaceae	<i>Lecythis lurida</i>	0,86
Lecythidaceae	<i>Lecythis pisonis</i>	0,86
Lecythidaceae	<i>Lecythis</i> sp.	0,82
Loganiaceae	<i>Strychnos subcordata</i>	0,64
Malvaceae	<i>Apeiba membranacea</i>	0,31
Malvaceae	<i>Apeiba petoumo</i>	0,64
Malvaceae	<i>Luehea speciosa</i>	0,5
Malvaceae	<i>Sterculia pruriens</i>	0,48
Malvaceae	<i>Theobroma glaucum</i>	0,64
Melastomataceae	<i>Mouriri collocarpa</i>	0,81
Meliaceae	<i>Carapa guianensis</i>	0,55
Meliaceae	<i>Guarea guidonia</i>	0,61
Menispermaceae	<i>Abuta grandifolia</i>	0,64
Moraceae	<i>Bagassa guianensis</i>	0,71
Moraceae	<i>Brosimum acutifolium</i>	0,62
Moraceae	<i>Brosimum guianense</i>	0,89
Moraceae	<i>Brosimum rubescens</i>	0,84
Moraceae	<i>Clarisia racemosa</i>	0,57
Moraceae	<i>Ficus maxima</i>	0,36
Moraceae	<i>Helicostylis</i> sp.	0,67
Moraceae	<i>Maquira coriacea</i>	0,54
Myristicaceae	<i>Virola michelii</i>	0,47
Myrtaceae	<i>Myrcia splendens</i>	0,8
Myrtaceae	<i>Myrciaria floribunda</i>	0,77
Nyctaginaceae	<i>Neea oppositifolia</i>	0,89
Ochnaceae	<i>Lacunaria jenmanii</i>	0,64
Ochnaceae	<i>Quiina florida</i>	0,64

Olacaceae	<i>Miconia guianensis</i>	0,77
Rhamnaceae	<i>Ziziphus</i> sp.	0,9
Rubiaceae	<i>Capirina decorticans</i>	0,59
Rubiaceae	<i>Chimarrhis turbinata</i>	0,72
Rubiaceae	<i>Coussarea brevicaulis</i>	0,64
Rutaceae	<i>Esenbeckia febrifuga</i>	0,64
Rutaceae	<i>Euxylophora paraensis</i>	0,66
Rutaceae	<i>Galipea trifoliata</i>	0,64
Rutaceae	<i>Zanthoxylum rhoifolium</i>	0,5
Salicaceae	<i>Laetia procera</i>	0,65
Sapotaceae	<i>Chrysophyllum sanguinolentum</i>	0,67
Sapotaceae	<i>Manilkara bidentata</i>	0,87
Sapotaceae	<i>Manilkara huberi</i>	0,93
Sapotaceae	<i>Micropholis crassipedicellata</i>	0,61
Sapotaceae	<i>Pouteria gongrijpii</i>	0,78
Sapotaceae	<i>Pouteria guianensis</i>	0,94
Sapotaceae	<i>Pouteria hispida</i>	0,87
Sapotaceae	<i>Pouteria oppositifolia</i>	0,65
Sapotaceae	<i>Pouteria reticulata</i>	0,79
Sapotaceae	<i>Pouteria retinervis</i>	0,78
Sapotaceae	<i>Pouteria</i> sp.	0,78
Sapotaceae	<i>Pradosia cochlearia</i>	0,73
Simaroubaceae	<i>Simaba cedron</i>	0,47
Urticaceae	<i>Cecropia engleriana</i>	0,49
Urticaceae	<i>Cecropia ficifolia</i>	0,27
Urticaceae	<i>Cecropia palmata</i>	0,3
Urticaceae	<i>Pourouma minor</i>	0,44
Urticaceae	<i>Pourouma villosa</i>	0,34
Violaceae	<i>Rinorea guianensis</i>	0,78
Violaceae	<i>Rinorea pubiflora</i>	0,75
Violaceae	<i>Rinorea racemosa</i>	0,68
Vochysiaceae	<i>Qualea paraensis</i>	0,67

APÊNDICE 2 – INTERVALOS DE CONFIANÇA DE ESTOQUES DE BIOMASSA POR CLASSE DIAMÉTRICA (MG HA⁻¹), PARA CADA EQUAÇÃO APLICADA A PARCELAS DE FLORESTA DENSA NA AMAZÔNIA BRASILEIRA. DADOS ORIUNDOS DO PROJETO PAISAGENS SUSTENTÁVEIS, DA EMBRAPA, PARA O BIOMA AMAZÔNIA.

Classes diamétricas	Número de árvores	Intervalos de Confiança (Limites inferiores e superiores) – Higuchi et al. (1998)	Intervalos de Confiança (Limites inferiores e superiores) – Chambers et al. (2001)	Intervalos de Confiança (Limites inferiores e superiores) – Silva (2007)
I	159	6,96 - 7,03	4,12 - 4,17	12,99 - 13,12
II	6.879	1.060,54 - 1.061,78	852,82 - 853,89	1.704,45 - 1.706,38
III	2.118	1.060,18 - 1.062,89	1.083,89 - 1.086,70	1.492,39 - 1.496,16
IV	1.337	1.513,19 - 1.518,18	1.712,85 - 1.718,51	1.939,56 - 1.945,93
V	1.143	2.100,99 - 2.108,56	2.413,73 - 2.422,43	2.545,52 - 2.554,67
VI	647	1.826,45 - 1.834,89	2.048,85 - 2.058,32	2.104,58 - 2.114,31
VI	273	1.112,15 - 1.120,62	1.183,21 - 1.192,22	1.227,63 - 1.236,98
VIII	126	694,94 - 702,78	690,11 - 697,87	740,37 - 748,71
IX	111	807,13 - 816,95	736,56 - 745,52	832,52 - 842,65

X	47	435,51 - 443,58	361,66 - 368,36	436,43 - 444,52
XI	57	1.054,84 - 1.075,20	568,47 - 577,90	962,57 - 980,44

APÊNDICE 3 – INTERVALOS DE CONFIANÇA DE ESTOQUES DE BIOMASSA POR CLASSE DIAMÉTRICA (MG HA⁻¹), PARA CADA EQUAÇÃO APLICADA A PARCELAS DE FLORESTA ABERTA NA AMAZÔNIA BRASILEIRA. DADOS ORIUNDOS DO PROJETO PAISAGENS SUSTENTÁVEIS, DA EMBRAPA, PARA O BIOMA AMAZÔNIA.

Classes diamétricas	Número de árvores	Intervalos de Confiança (Limites inferiores e superiores) – Nogueira et al. (2008) Equação 1	Intervalos de Confiança (Limites inferiores e superiores) – Nogueira et al. (2008) Equação 2
I	275	32,34 - 32,56	21,12 - 21,26
II	88	34,24 - 34,69	21,56 - 21,84
III	124	130,61 - 131,95	79,70 - 80,51
IV	146	249,17 - 251,40	149,71 - 151,05
V	75	205,76 - 208,69	121,74 - 123,47
VI	41	167,86 - 171,16	98,03 - 99,96
VI	26	144,50 - 148,11	83,56 - 85,64
VIII	7	50,56 - 52,94	28,96 - 30,33
IX	7	68,82 - 72,17	39,04 - 40,95
X	10	183,20 - 191,05	101,79 - 106,13

APÊNDICE 4 – ESTOQUES DE BIOMASSA, CARBONO E EMISSÕES DE CO_{2eq} (Mg), ESTIMADOS A PARTIR DAS EQUAÇÕES DE HIGUCHI ET AL. (1998), CHAMBERS ET AL. (2001) E SILVA (2007), PARA 1.158 PARCELAS DE FLORESTA DENSA NA AMAZÔNIA BRASILEIRA. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA.

Mg ha⁻¹

Classes diamétricas	Biomassa			Carbono		
	Higuchi et al. (1998)	Chambers et al (2001)	Silva (2007)	Higuchi et al. (1998)	Chambers et al. (2001)	Silva (2007)
I	32.190,93	36.409,57	41.323,74	15.451,18	17.476,06	19.834,78
II	35.191,74	40.443,24	42.613,71	16.897,91	19.419,50	20.461,66
III	28.806,19	32.321,05	33.193,61	13.828,66	15.516,00	15.934,88
IV	22.022,02	23.516,79	24.359,76	10.569,52	11.286,93	11.691,52
V	19.167,98	18.917,14	20.369,55	9.188,97	9.068,83	9.765,04
VI	10.546,19	9.445,90	10.810,64	5.057,84	4.530,13	5.184,65
VII	8.621,15	7.073,15	8.610,06	4.135,03	3.392,65	4.129,74
VIII	4.807,47	3.603,36	4.692,22	2.307,35	1.729,59	2.252,08
IX	4.364,49	2.961,64	4.166,00	2.099,46	1.424,76	2.004,02
X	3.987,98	2.400,12	3.717,00	1.910,95	1.149,98	1.781,07
XI	1.843,38	1.009,81	1.689,30	884,22	484,31	810,29
XII	2.390,07	1.164,64	2.148,25	1.145,09	557,98	1.029,24
XIII	7.041,40	2.264,37	5.955,25	3.377,59	1.086,13	2.856,60
Total	180.980,98	181.530,77	203.649,09	86.853,76	87.122,85	97.735,57

APÊNDICE 4 – CONTINUAÇÃO.

Mg

Classes diamétricas	CO _{2eq}		
	Higuchi et al. (1998)	Chambers et al. (2001)	Silva (2007)
I	56.656,04	64.080,84	72.729,78
II	61.937,46	71.180,10	75.000,14
III	50.698,89	56.885,04	58.420,76
IV	38.758,75	41.389,55	42.873,18
V	33.735,65	33.294,17	35.850,41
VI	18.561,29	16.624,79	19.026,72
VII	15.173,22	12.448,74	15.153,70
VIII	8.461,15	6.341,91	8.258,30
IX	7.681,50	5.212,49	7.332,17
X	7.018,84	4.224,21	6.541,92
XI	3.244,35	1.777,26	2.973,16
XII	4.206,52	2.049,77	3.780,92
XIII	12.392,86	3.985,30	10.481,25
Total	318.526,53	319.494,16	358.422,41

APÊNDICE 5 – ESTOQUES DE BIOMASSA, CARBONO E EMISSÕES DE CO_{2eq} (Mg), ESTIMADOS A PARTIR DAS EQUAÇÕES DE NOGUEIRA ET AL. (2008) EQUAÇÃO 1 E NOGUEIRA ET AL. (2008) EQUAÇÃO 2, PARA 854 PARCELAS DE FLORESTA ABERTA NA AMAZÔNIA BRASILEIRA. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA.

Mg						
Classes diamétricas	Biomassa		Carbono		CO _{2eq}	
	Nogueira et al. (2008) Equação 1	Nogueira et al. (2008) Equação 2	Nogueira et al. (2008) Equação 1	Nogueira et al. (2008) Equação 2	Nogueira et al. (2008) Equação 1	Nogueira et al. (2008) Equação 2
I	17.601,67	10.767,42	8.448,80	5.168,36	30.978,95	18.950,66
II	19.455,87	11.688,44	9.338,82	5.610,45	34.242,33	20.571,65
III	17.417,47	10.308,39	8.360,38	4.948,03	30.654,74	18.142,77
IV	14.162,58	8.275,79	6.798,04	3.972,38	24.926,15	14.565,39
V	12.514,27	7.225,83	6.006,85	3.468,40	22.025,12	12.717,45
VI	7.646,53	4.366,36	3.670,34	2.095,85	13.457,90	7.684,79
VII	6.615,30	3.747,11	3.175,34	1.798,61	11.642,93	6.594,91
VIII	4.295,57	2.415,92	2.061,87	1.159,64	7.560,21	4.252,02
IX	3.633,61	2.030,01	1.744,13	974,40	6.395,15	3.572,81
X	3.625,05	2.010,12	1.740,03	964,86	6.380,10	3.537,81
XI	1.510,76	833,43	725,17	400,04	2.658,95	1.466,83
XII	2.092,10	1.147,20	1.004,21	550,66	3.682,10	2.019,07
XIII	4.941,72	2.660,21	2.372,03	1.276,90	8.697,43	4.681,97
Total	115.512,52	67.476,22	55.446,01	32.388,58	203.302,04	118.758,14

APÊNDICE 6 – INTERVALOS DE CONFIANÇA DE ESTOQUES DE BIOMASSA POR CLASSE DIAMÉTRICA (MG HA⁻¹), PARA CADA EQUAÇÃO APLICADA A PARCELAS DE FLORESTA DENSA NA AMAZÔNIA BRASILEIRA. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA.

Classes diamétricas	Número de árvores	Intervalos de Confiança (Limites inferiores e superiores) – Higuchi et al. (1998)	Intervalos de Confiança (Limites inferiores e superiores) – Chambers et al. (2001)	Intervalos de Confiança (Limites inferiores e superiores) – Silva (2007)
I	28.737	32.181,81 - 32.200,05	36.399,22 - 36.419,1	41.312,08 - 41.335,40
II	19.010	35.178,15 - 35.205,33	40.427,62 - 40.458,86	42.597,29 - 42.630,14
III	10.172	28.789,12 - 28.823,26	32.301,93 - 32.340,16	33.173,98 - 33.213,24
IV	5.476	22.003,84 - 22.040,19	23.497,41 - 23.536,17	24.339,68 - 24.379,85
V	3.389	19.147,32 - 19.188,65	18.896,79 - 18.937,49	20.347,62 - 20.391,49
VI	1.367	10.527,97 - 10.564,41	9.429,62 - 9.462,18	10.791,97 - 10.829,30
VI	896	8.603,55 - 8.638,74	7.058,71 - 7.087,60	8.592,48 - 8.627,63
VIII	410	4.792,57 - 4.822,37	3.592,19 - 3.614,52	4.677,68 - 4.706,75
IX	308	4.349,20 - 4.379,78	2.951,28 - 2.979,01	4.151,41 - 4.180,60

X	229	3.971,01 - 4.004,94	2.389,92 - 2.410,32	3.701,19 - 3.732,81
XI	92	1.831,47 - 1.855,30	1.003,28 - 1.016,33	1.678,38 - 1.700,21
XII	101	2.375,38 - 2.404,76	1.157,50 - 1.171,78	2.135,05 - 2.161,45
XIII	184	7.007,69 - 7.075,11	2.254,17 - 2.274,58	5.927,17 - 5.983,33

APÊNDICE 7 – INTERVALOS DE CONFIANÇA DE ESTOQUES DE BIOMASSA POR CLASSE DIAMÉTRICA (MG HA⁻¹), PARA CADA EQUAÇÃO APLICADA A PARCELAS DE FLORESTA ABERTA NA AMAZÔNIA BRASILEIRA. DADOS ORIUNDOS DO PROJETO RADAMBRASIL, PARA O BIOMA AMAZÔNIA.

Classes diamétricas	Número de árvores	Intervalos de Confiança (Limites inferiores e superiores) – Nogueira et al. (2008) Equação 1	Intervalos de Confiança (Limites inferiores e superiores) – Nogueira et al. (2008) Equação 2
I	28.737	17.595,32 - 17.608,03	10.763,54 - 10.771,30
II	19.010	19.446,27 - 19.465,47	11.682,67 - 11.694,20
III	10.172	17.404,33 - 17.430,60	10.300,62 - 10.316,16
IV	5.476	14.148,26 - 14.176,90	8.267,42 - 8.284,16
V	3.389	12.497,69 - 12.530,86	7.216,25 - 7.235,40
VI	1.367	7.631,38- 7.661,69	4.357,70 - 4.375,01
VI	896	6.598,99 - 6.631,61	3.737,87 - 3.756,35
VIII	410	4.280,44 - 4.310,71	2.407,41 - 2.424,43
IX	308	3.618,65 - 3.648,56	2.021,65 - 2.038,36
X	229	3.607,78 - 3.642,33	2.000,54 - 2.019,70

XI	92	1.498,35 - 1.523,18	826,58 - 840,28
XII	101	2.076,66 - 2.107,55	1.138,73 - 1.155,67
XIII	184	4.907,91 - 4.975,54	2.642,12 - 2.678,30